SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 3007

PROCJENA PERFORMANSI STRUJANJA IGARA ZASNOVANIH NA RAČUNALNOM OBLAKU TEMELJENA NA ANALIZI KRIPTIRANOG PROMETA UPORABOM METODA STROJNOG UČENJA

Stipe Paradžik

Zagreb, lipanj 2022.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 3007

PROCJENA PERFORMANSI STRUJANJA IGARA ZASNOVANIH NA RAČUNALNOM OBLAKU TEMELJENA NA ANALIZI KRIPTIRANOG PROMETA UPORABOM METODA STROJNOG UČENJA

Stipe Paradžik

Zagreb, lipanj 2022.

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Zagreb, 11. ožujka 2022.

DIPLOMSKI ZADATAK br. 3007

Pristupnik: **Stipe Paradžik (0036508032)**

Studij: Računarstvo

Profil: Programsko inženjerstvo i informacijski sustavi

Mentorica: prof. dr. sc. Lea Skorin-Kapov

Zadatak: **Procjena performansi strujanja igara zasnovanih na računalnom oblaku temeljena na analizi kriptiranog prometa uporabom metoda strojnog učenja**

Opis zadatka:

Igre zasnovane na računalnom oblaku (engl. cloud gaming) su usluga mrežnog igranja koja omogućuje strujanje sadržaja igre od poslužitelja do klijenta u obliku video sadržaja, dok se kontrole za igranje šalju u suprotnom smjeru. Napredne mogućnosti takve usluge rezultiraju visokim zauzećem širine propusnog pojasa mreže i strogim zahtjevima za niskim mrežnim kašnjenjem. Davatelji mrežnih usluga u pravilu nemaju direktan uvid u performanse i parametre kvalitete usluge, jer je promet najčešće kriptiran. Rješenja koja koriste metode strojnog učenja za procjenu kvalitete temeljem analize značajki mrežnog prometa mogla bi riješiti ovaj problem. Za potrebe istraživanja, na Zavodu za telekomunikacije je prikupljen velik skup podataka koji sadrži videosadržaj igranja, zapise o aplikacijskim performansama strujanja, mrežni promet snimljen za vrijeme igranja te zapise korisničkih interakcija. Prvi dio zadatka je analizirati prikupljeni skup podataka. Prilikom analize videosadržaja koristit će se dva skupa objektivnih video metrika koje služe za izračun vremenske i prostorne složenosti videosadržaja. Nadalje, potrebno je odabrati relevantne značajke mrežnog prometa i testirati do koje se mjere performanse na razini aplikacije (npr. rezolucija, brzina kodiranja) te žanr igre mogu procijeniti na temelju prometnih značajki uporabom metoda strojnog učenja.

Rok za predaju rada: 27. lipnja 2022.

Sadržaj

Uvod 1

1. Računalni oblak 2

2. Igre zasnovane na računalnom oblaku 4

2.1. Komercijalna rješenja 5

3. Strojno učenje 6

4. Prikupljeni skup podataka 8

4.1. Platforma Steam 8

4.2. Steam Remote Play 8

4.3. Prikupljanje podataka 10

4.3.1. Analizirane igre 10

4.3.2. Snimanje video sadržaja 11

4.3.3. Snimanje mrežnog prometa 11

4.3.4. Snimanje korisničkog unosa miša i tipkovnici 12

4.3.5. Steam Stream Log 12

5. Analiza prikupljenih podataka 14

5.1. Analiza video sadržaja 14

5.1.1. Analizirane video metrike 14

5.1.2. Prostorna i vremenska analiza: PFIM i IBS metrike 16

5.1.3. Prostorna i vremenska analiza: SI i TI metrike 25

5.2. Analiza mrežnog prometa 33

5.2.1. Analiza mrežnog prometa u smjeru poslužitelj-klijent 33

5.2.2. Analiza mrežnog prometa u smjeru klijent-poslužitelj 39

5.3. Sažetak ključnih zaključaka 40

6. Procjena parametara korištenjem metoda strojnog učenja 41

6.1. Korišteni alati 41

6.2. Priprema ulaznih podataka 41
6.3. Ocjenjivanje modela strojnog učenja 43
6.4. Korišteni algoritmi 44
6.5. Analiza performansi modela 45
6.5.1. Predviđanje parametra brzine kodiranja 45
6.5.2. Predviđanje parametra broj okvira u sekundi 51
6.5.3. Previđanje parametra rezolucije 53
6.5.4. Sažetak ključnih zaključaka 55
7. Sažetak 57
8. Summary 58
Literatura 59
Popis slika 63
Popis tablica 66

Uvod

Igre zasnovane na računalnom oblaku (engl. *cloud gaming*) su oblik mrežnog igranja, u kojem se igra pokreće na poslužiteljskom računalu i snima se video sadržaj igre, te se šalje s poslužitelja na klijentski uređaj putem mreže, a klijent poslužitelju šalje kontrole za igranje igre. Ovaj način igranja raste u popularnosti jer korisnicima omogućava pristup velikom broju igara bez obzira na uređaj koji koriste i mjesto na kojem se nalaze [46]. Za izdavače igara ovaj model je također pogodan jer se pri izradi igara mogu usredotočiti na samo jednu platformu. Igre također imaju priliku biti izložene većoj publici.

Na Zavodu za telekomunikacije[1] [21] prikupljen je video sadržaj, mrežni promet i korisničke kontrole pri korištenju Steam Remote Play [25] usluge. Cilj ovoga rada je vidjeti kako različiti parametri (brzina kodiranja videa, broj okvira u sekundi, rezolucija) utječu na metrike prostorne i vremenske složenosti videozapisa. Promet koji se odvija između poslužitelja i klijenta je kriptiran, tako da davatelji mrežnih usluga nemaju uvid u kvalitetu usluge, iz toga razloga metodama strojnog učenja pokušat će se iz mrežnog prometa predvidjeti postavke korisničkih parametara. Također će biti provedena analize mrežnog prometa, kako bi ustanovili parametre koji imaju najviše utjecaja na mrežni promet.

U prvom poglavlju rada opisan je pojam računalnog oblaka, zatim su objašnjeni pojmovi igra zasnovanih na računalnom oblaku i strojnog učenja. U četvrtom poglavlju objašnjeni su alati i način prikupljanja podataka. U petom poglavlju objašnjene su metrike prostorne i vremenske složenosti, zatim je provedena analiza videozapisa i mrežnog prometa. U šestom poglavlju su objašnjene metode koje su se koristile prilikom strojnog učenja i provedena je analiza rezultata dobivenih metodama strojnog učenja.

[1] https://muexlab.fer.hr/muexlab/research/datasets

1. Računalni oblak

Računalni oblak možemo definirati kao model za omogućavanje pristupa korisnicima putem mreže skupu računalnih resursa koji se mogu konfigurirati (npr. mreže, aplikacije, usluge, memorije za pohranu podataka i poslužitelja) [1]. Postoji pet karakteristika koje definiraju računalni oblak:

1) Samoposluživanje na zahtjev (engl. *On-demand self-service*) – korisnik može pristupiti računalnim resursima, bez potrebne dodatne ljudske interakcije s davateljima usluge.
2) Široki pristup mreži (engl. *Broad network access*) – mogućnosti oblaka su dostupne preko mreže i pristup se ostvaruje kroz standardne mehanizme koji promiču upotrebu heterogenih platformi tankih klijenata (engl. *thin client*) ili debelih klijenata (engl. *thick client*).
3) Udruživanje resursa (engl. *Resource pooling*) – računalni resursi se objedinjuju kako bi posluživali više potrošača, gdje se različiti fizički i virtualni resursi dinamički raspoređuju po potrebama i potražnjama potrošača. Korisnik ne bi trebao moći kontrolirati ili znati lokaciju resursa.
4) Brza elastičnost (engl. *Rapid elasticity*) – resursi se mogu elastično osigurati i osloboditi ovisno o potražnji. Korisniku se količina resursa može činiti neograničena.
5) Izmjerena usluga (engl. *Measured service*) – računalni oblak automatski kontrolira i optimizira korištenje resursa, tako da radi mjerenja korištenja nad resursima bitnim za tu uslugu (npr. slobodni prostor za pohranu podataka, propusnost (engl. *throughput*), dostupna procesorska snaga i broj aktivnih korisnika).

Tri su osnovna modela usluga računalnog oblaka: softver kao usluga – *SaaS* (engl. *Software as a Service*), platforma kao usluga - *PaaS* (engl. *Platform as a Service*) i infrastruktura kao usluga - *IaaS* (engl. *Infrastructure as a Service*). Software kao uslugu obilježava korisnički pristup usluzi korištenjem tankog klijenta (najčešće web preglednika), te korisnik nema nikakvu kontrolu nad infrastrukturom oblaka (mrežom, poslužiteljima, operacijskim sustavom), već samo nekim ograničenim korisničkim postavkama unutar same aplikacije. Primjeri *SaaS* aplikacija su Slack [2], HubSpot [3] i

Dropbox [4]. Platforma kao usluga pruža mogućnosti implementacije u oblaku (engl. *deploy onto the cloud*) aplikacija koje su kreirali korisnici. Potrošač nema kontrolu nad temeljnom infrastrukturom oblaka, ali ima kontrolu nad implementiranim aplikacijama. Primjeri ovakvih usluga su Microsoft Azure [5], Google App Engine [6] i AWS Elastic Beanstalk [7]. Infrastruktura kao usluga omogućava korisnicima pokretanje proizvoljnog softvera u oblaku. Korisnik može upravljati nad operacijskim sustavom, memorijom za pohranu i implementiranim aplikacijama. Primjeri ovih usluga su AWS EC2 [8], Microsoft Azure i Google Compute Engine [9].

Postoje 4 načina pristupa računalnom oblaku: privatni oblak (engl. *private cloud*), javni oblak (engl. *public cloud*), hibridni oblak (engl. *hybrid cloud*) i oblak zajednice (engl. *community cloud*) [1]. Privatni oblak je namijenjen korištenju samo jednoj organizacije (najčešće tvrtki). Unutar same organizacije može biti više korisnika kojima je dopušten pristup oblaku. Održavanje i vlasništvo oblaka ne mora biti nužno vezano za samu organizaciju, već može biti u rukama neke druge organizacije. Javni oblak je namijenjen za upotrebu od strane šire javnosti. Može biti u vlasništvu tvrtke ili neke druge organizacije (državne, akademske). Hibridni oblak sastavljen je od dva ili više različitih oblaka. Ideja je da su neke usluge javno dostupne, a neki podatci koji ne bi trebali biti dostupni široj javnosti pohranjuju i obrađuju se u privatnom oblaku. Oblak zajednice namijenjen je za korištenje samo unutar neke zajednice, primjer je IBM SoftLayer [10] koji je isključivo namijenjen za upotrebu od strane američkih saveznih agencija.

Korisnicima je često puno isplativije koristiti usluge računalnog oblaka nego raditi vlastitu infrastrukturu. Industrija računalnog oblaka trenutno vrijedi oko 450 milijardi dolara i predviđa se da će do 2026. godine vrijediti oko 950 milijardi dolara [11].

2. Igre zasnovane na računalnom oblaku

Igre zasnovane na računalnom oblaku (engl. *cloud gaming*) rade tako da korisnik preko aplikacije na svom uređaju šalje naredbe preko Interneta u računalni oblak gdje je pokrenuta igra [12]. U računalnom oblaku obrađuju se korisničke naredbe i izvršava logika igre. Unutar igre se prikaže nova scena koja se zatim snimi, te kodira u video. Kodirani video se šalje nazad na korisničku aplikaciju, gdje se dekodira i prikazuje korisniku. Ovaj proces prikazan na slici 2.1 se ponavlja sve dok postoji veza između aplikacije i računalnog oblaka.

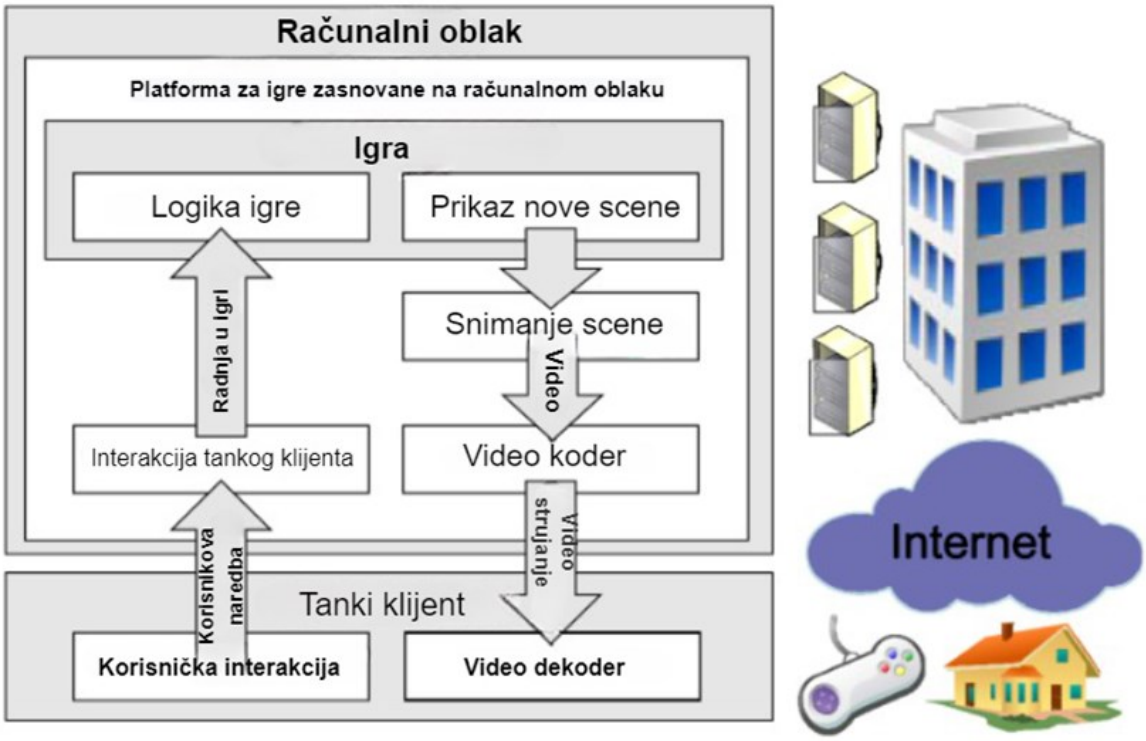

Slika 2.1 Arhitektura igara zasnovanih na računalnom oblaku [46]

Ovaj način igranja korisnicima olakšava pristup igrama, bez potrebe za posjedovanjem snažnih računalnih komponenti, koje su tijekom pandemije značajno poskupjele te im se smanjila dostupnost [13]. U velikom broju slučaja potrebno je samo imati uređaj koji ima Internet preglednik i Internetsku vezu. Dolaskom 5G mreže ovaj oblik igranja bi trebao biti još dostupniji, pogotovo na pametnim mobitelima kada je korisnik izvan svoga doma.

2.1. Komercijalna rješenja

Gaikai i OnLive su bili među prvim servisima koji su nudili uslugu igara zasnovanih na računalnom oblaku. Oba su se pojavila oko 2009. godine, no imali su različite poslovne modele. Na OnLive servisu postojala je digitalna trgovina preko koje bi korisnik mogao kupiti željene igre. Gaikai je radio više kao platforma za oglašavanje, korisnicima su se nudile besplatne demo verzije igara, te bi poslije igranja postojala opcija kupnje igre za neku drugu platformu. Obje kompanije je preuzeo Sony, te njihove tehnologije implementirao u svoju platformu PlayStation Now [14]. PlayStation Now je nastao 2014. godine, te trenutno ima oko 3 milijuna korisnika [15]. Dostupan je na PS5, PS4 i Windows platformama, radi na modelu mjesečne pretplate i nudi igranje PS2, PS3 i PS4 igara.

Google 2019. na tržište predstavlja svoj servis Stadia [16]. Korisnik može kupiti igre za Stadia platformu, ili platiti mjesečnu pretplatu gdje dobije pristup određenim igrama. Nvidia od 2012. godine razvija uslugu GeForce Now [17], 2020. godine usluga izlazi iz beta testiranja i postaje javno dostupna. Nudi 3 razine pretplate FREE, PRIORITY i RTX 3080. Korisnik ako odluči platiti pretplatu dobiva snažnije računalo s boljim performansama, duže maksimalno trajanje jedne sjednice, veće maksimalne rezolucije i veći broj okvira u sekundi (engl. *framerate*). Pri korištenju usluge potrebno je povezati GeForce Now s nekom od digitalnih trgovina (Steam, Epic Games, Origin) te korisnik može igrati igre koje posjeduje u tim trgovinama. GeForce Now trenutno ima preko 14 milijuna korisnika [18]. Amazon 2020. godine predstavlja Amazon Luna [19] servis, gdje se plaća mjesečna pretplata kako bi se dobio pristup određenoj selekciji igara. Microsoft također ima svoju platformu Xbox Cloud Gaming [20], koja je još u fazi beta testiranja. Xbox Cloud Gaming trenutno dolazi kao jedna od pogodnosti Xbox Game Pass Ultimate pretplate.

Igre zasnovane na računalnom oblaku su brzo rastuća industrija, samo servis GeForce Now je udvostručio broj korisnika unutar godine dana [18]. Većina servisa se pojavila u prošle dvije godine, i vidljivo je da ne postoji neki standard u načinu naplaćivanja servisa, već svaka platforma nudi nešto drugačije.

3. Strojno učenje

Strojno učenje (engl. *Machine learning*) možemo definirati kao sposobnost sustava da uči iz podataka specifičnih za problem kako bi rješavao zadatke vezane uz problem i automatizirao proces izgradnje analitičkog modela [32]. Strojno učenje ima veliki broj različitih primjena, kao što su: klasifikacija teksta ili dokumenata, obrada prirodnog jezika (engl. *Natural language processing - NLP*), računalni vid, otkrivanje prijevare za kreditne kartice, medicinska dijagnoza, sustav preporuke i mnoge druge [33].

Može se izdvojiti 5 standardnih vrsta zadataka strojnog učenja [33]:

1) Klasifikacija (engl. *Classification*): Dodjela pojedine kategorije svakoj stavci. Primjer: dodjela kategorije vozilu (automobil, brod, zrakoplov).
2) Regresija (engl. *Regression*): Predviđanja vrijednosti za svaku stavku. Primjer: predviđanje cijene dionice.
3) Rangiranje (engl. *Ranking*): Učenje rasporeda stavki prema nekom kriteriju. Primjer: vraćanje i rangiranje web stranica relevantnih za upit.
4) Grupiranje (engl. *Clustering*): Problem podjele skupa stavki na podskupove. Primjer: društvene mreže, pokušaj određivanja prirodne zajednice unutar velikih skupova ljudi.
5) Smanjenje dimenzionalnosti ili višestruko učenje (engl. *Dimensionality reduction or manifold learning*): Transformacija početne stavke u prikaz niže dimenzije uz očuvanje nekih svojstava originalnog prikaza. Primjer: obrada digitalnih slika u zadatcima računalnog vida.

Dodatno možemo odraditi podjelu po načinu učenja [33]:

1) Nadzirano učenje (engl. *supervised learning*): Podatci za učenje su sastavljeni od ulaznih vrijednosti i očekivanih izlaznih vrijednosti. Ova vrsta učenja najčešće se primjenjuje za probleme klasifikacije, regresije i problema rangiranja.
2) Nenadzirano učenje (engl. *unsupervised learning*): Podatci za učenje nemaju označene očekivane izlazne podatke, pa zbog toga je teško ocijeniti kvalitetu predviđanja. Primjeri ove vrste učenja su grupiranje i smanjenje dimenzionalnosti.

3) Polunadzirano učenje (engl. *semi-supervised learning*): U podatcima za učenje postoje stavke koji imaju očekivane izlazne vrijednosti i stavke koje su bez izlaznih vrijednosti.
4) Transduktivno zaključivanje (engl. *transductive inference*): Ulazni podatci su kao u polunadziranom učenju, ali cilj transduktivnog zaključivanja je predvidjeti izlazne vrijednosti samo za određene ispitne podatke.
5) On-line učenje: Postoji više faza u kojima se isprepleću obuka i testiranje. U svakoj fazi sustav dobije podatke bez izlaznih vrijednosti, napravi predikciju, zatim dobiva pravu vrijednost i uči iz nje.
6) Podržano učenje (engl. *reinforcement learning*): Faze obuke i testiranja su također isprepletene, ali se ne pruža dugoročna informacija o uspjehu, što potiče više istraživanja pri donošenju odluke.
7) Aktivno učenje: sustav adaptivno ili interaktivno prikuplja primjere obuke. Cilj je postizanje rezultata sličnih nadziranim učenjem, ali s manje testnih primjera.

4. Prikupljeni skup podataka

U ovom poglavlju je opisan način i programi koji su korišteni pri prikupljanju podataka. Prikupljanje podataka je obavljeno prije izrade ovoga rada na Zavodu za telekomunikacije[2] [21], te cilj ovoga rada je provesti analizu nad tim podatcima.

4.1. Platforma Steam

Steam [22] je nastao 2003. godine kao alat za zaštitu protiv piratizacije igara (engl. *Digital rights management, DRM*), te je prerastao u najveću platformu za prodaju digitalnih igara, s preko 120 milijuna mjesečno aktivnih korisnika [23]. Steam Link [24] je njihov prvi pokušaj strujanja igara zasnovanih na računalnom oblaku. Izlazi na tržište 2015. godine, te omogućuje korisniku strujanje Steam igara s osobnog računala na Steam Link uređaj.

4.2. Steam Remote Play

Steam Remote Play [25] je usluga platforme Steam koja omogućava strujanje igre s osobnog računala na sve uređaje koje podržavaju Steam ili Steam Link aplikaciju. Trenutno postoji podrška za iOS, Android, Windows, MacOS, Linux i Raspberry Pi uređaje. Ova usluga nastala je 2019. godine kada prestaje prodaja Steam Link uređaja. Ime Steam Link dano je aplikacijama za iOS, Android i Raspberry Pi koje omogućavaju Remote Play. Dodatno Remote Play ima opciju Remote Play Together, koja omogućava korisnicima zajedničko igranja s više igrača, gdje jedan igrač ima ulogu poslužitelja na čijem se računalu pokreće igra, a ostali igrači su klijenti koji se spajaju preko Interneta. Prilikom strujanja igara Steam aplikacija sama pokuša odabrati najpovoljnije parametre, no korisniku je omogućeno da u klijentskoj aplikaciji odabere brzinu kodiranja videa, rezoluciju i broj okvira u sekundi. Podržano je ograničavanje brzine kodiranja (engl. *bitrate*) na 3 Mbit/s pa do 75 Mbit/s ili opcija *Unlimited*. Također je podržan veliki broj rezolucija: od 852x480 (480p) pa sve do 7680x4320 (8K). Najniže ograničenje broja

[2] https://muexlab.fer.hr/muexlab/research/datasets

okvira u sekundi je 30 fps (engl. *frames per second*), dok je najviše 120 fps. Sve opcije su prikazane u tablici 4.1.

Tablica 4.1 Steam Link dostupna ograničenja brzine kodiranja, broja okvira u sekundi i rezolucije

Brzine kodiranja	Broj okvira u sekundi	Rezolucije
3 Mbit/s	30 fps	852x480 (480p)
5Mbit/s	60 fps	1280x720 (720p)
10 Mbit/s	49.75 fps	1600x900 (900p)
15 Mbit/s	50 fps	1920x1080 (1080p)
20 Mbit/s	59.75 fps	2287x1080
25 Mbit/s	60 fps	2560x1440 (1440p)
30 Mbit/s	90 fps	3840x2160 (4K)
40 Mbit/s	120 fps	7680x4320 (8K)
50 Mbit/s		
75 Mbit/s		
Unlimited		

Na Slici 4.1 je prikazana arhitektura rada Steam Remote Play usluge. Korisnik na svom uređaju šalje naredbe preko Interneta na osobno računalo gdje je pokrenuta igra. Na računalu se obrade korisničke naredbe, izvrši nova scena unutar igre, zatim slijedi snimanje i kodiranje videa, koji se natrag preko Interneta šalje na korisnički uređaj, gdje se video dekodira i prikazuje na korisničkom zaslonu. Za kodiranje videa se koristi kodek H.264 [25].

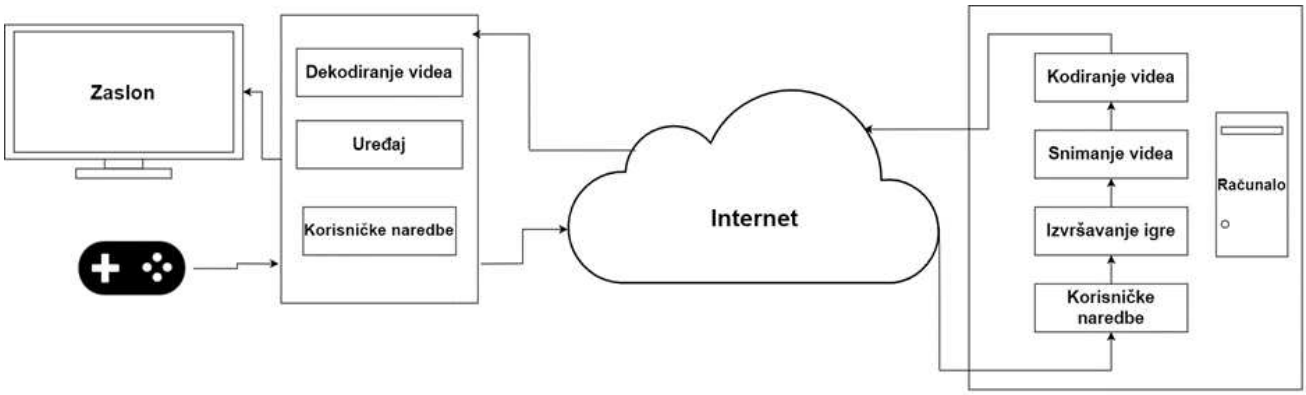

Slika 4.1 Steam Remote Play arhitektura [25]

4.3. Prikupljanje podataka

Usluga Steam Remote Play korisnicima nudi opcije odabira željene brzine kodiranja, rezolucije igre i broja okvira u sekundi. Za potrebe snimanja korištene su rezolucije 1280x720 (720p) i 1920x1080 (1080p), odabrane brzine kodiranja su bile 5 Mbit/s, 10 Mbit/s i 20 Mbit/s, dok broj okvira u sekundi je bio ograničen na 30 fps i 60 fps. Ukupno je bilo 12 različitih kombinacija brzine kodiranja, rezolucije i broja okvira u sekundi. U svakoj igri je napravljeno po 5 različitih snimanja za svaku kombinaciju brzine kodiranja, rezolucije i broja okvira, što dovodi do ukupno 60 snimanja po igri. Svako snimanje je trajalo 30 sekundi.

Poslužiteljsko računalo (Windows 10 operacijski sustav s Intel 3.6 Ghz i7-4790 procesorom, 16GB RAM-a i NVIDIA GeForce GTX 1060 3GB GPU) i klijentsko računalo su bili povezani putem LAN-a, oboje pomoću žičane veze. Na klijentskom računalu za prikupljanje podataka koristili su se sljedeći programi: Wireshark [26] (snimanje mrežnog prometa), FRAPS [27] (snimanje video sadržaja) i Macro Recorder [28] (snimanje korisničkih kontrola).

4.3.1. Analizirane igre

Za analizu je odabrano 20 igara iz različitih žanrova, različitih razina vizualne složenosti i dinamike igranja. U svrhu ovoga rada igre su razvrstane po položaju kamere koji se koristi unutar igre. Sve igre su navedene u tablici 4.2.

Tablica 4.2 Testirane igre

Položaj kamere	Naziv igre
Igre iz prvog lica (engl. *First person games*)	Borderlands 2, Burnout Paradise, Deus Ex Mankind Divided, Doom, Prey
Igre iz trećeg lica (engl. *Third person games*)	Alan Wake, Batman Arkham Knight, Darksiders 3, Dirt 5, Mass Effect 2, Rock of Ages, Tomb Raider
Pogled odozgo prema dolje (engl. *Top-Down games*)	Company of Heroes 2, Divinity Original Sin, Dota 2, Endless Space 2, Grim Dawn, Red Alert 3, Ring of Pain, Shadow Tactics

4.3.2. Snimanje video sadržaja

Video sadržaj koji je korisnik primao od poslužitelja snimljen je koristeći program FRAPS. Cilj ove vrste snimanja je pohraniti video koji korisnik vidi, kako bi se poslije mogao analizirati utjecaj promjene parametara na njegovu kvalitetu. Svaki video je spremljen u *.avi* formatu. Za svaku igru napravljeno je po 60 snimanja, te je analizirano 20 igara, tako da je ukupna količina prostora koji snimljeni video podatci zauzimaju približno 1.5 TB.

4.3.3. Snimanje mrežnog prometa

Koristeći program Wireshark na klijentskom računalu snimljen je sav odlazni i dolazni promet tijekom jedne sjednice. Promet je spremljen u *.pcap* datoteku (Slika 4.2), te je poslije filtriran po MAC adresama koristeći alat TShark [29], kako bi sadržavao samo dvosmjerni promet koji se odvijao između poslužitelja i klijenta. Iz *.pcap* datoteka vidimo da se koristi UDP protokol za razmjenu paketa između poslužitelja i klijenta. Iz takvog filtriranog prometa dobivena je *.csv* datoteka, koja se poslije koristila u analizi podataka. Ukupno je odrađeno oko 1200 snimanja mrežnog prometa, tako da ukupna količina prostora koje zauzimaju *.pcap* datoteke je oko 40 GB.

No.	Time	Source	Destination	Protocol	Length	Info
28	0.054338	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
29	0.055126	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
30	0.057581	146.66.155.66	10.19.128.131	UDP	240	27037 → 63694 Len=198
31	0.059369	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
32	0.060729	10.19.128.131	192.168.0.175	STUN	138	Binding Request user: 1Hjcu:H5jvq
33	0.063427	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
34	0.066628	146.66.155.66	10.19.128.131	UDP	1275	27037 → 63694 Len=1233
35	0.066852	146.66.155.66	10.19.128.131	UDP	1271	27037 → 63694 Len=1229
36	0.067036	146.66.155.66	10.19.128.131	UDP	1271	27037 → 63694 Len=1229
37	0.067036	146.66.155.66	10.19.128.131	UDP	933	27037 → 63694 Len=891
38	0.067114	10.19.128.131	146.66.155.66	UDP	86	63694 → 27037 Len=44
39	0.067288	146.66.155.66	10.19.128.131	UDP	1275	27037 → 63694 Len=1233
40	0.067288	146.66.155.66	10.19.128.131	UDP	329	27037 → 63694 Len=287
41	0.067496	146.66.155.66	10.19.128.131	UDP	584	27037 → 63694 Len=542
42	0.068358	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
43	0.068887	146.66.155.66	10.19.128.131	R-GOOSE	235	
44	0.074304	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
45	0.077218	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
46	0.081786	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
47	0.082589	146.66.155.66	10.19.128.131	UDP	236	27037 → 63694 Len=194
48	0.082589	146.66.155.66	10.19.128.131	UDP	237	27037 → 63694 Len=195
49	0.082589	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
50	0.086277	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
51	0.090504	146.66.155.66	10.19.128.131	UDP	239	27037 → 63694 Len=197
52	0.095256	10.19.128.131	146.66.155.66	UDP	147	63694 → 27037 Len=105
53	0.095614	146.66.155.66	10.19.128.131	UDP	88	27037 → 63694 Len=46
54	0.099078	146.66.155.66	10.19.128.131	UDP	1275	27037 → 63694 Len=1233
55	0.099268	146.66.155.66	10.19.128.131	UDP	1271	27037 → 63694 Len=1229
56	0.099268	146.66.155.66	10.19.128.131	UDP	1271	27037 → 63694 Len=1229
57	0.099268	146.66.155.66	10.19.128.131	UDP	933	27037 → 63694 Len=891

```
> Frame 1: 1275 bytes on wire (10200 bits), 1275 bytes captured (10200 bits) on interface \Device\NPF_{E48C08C9-5F90-405F-B39E-B040D5EF95DB}, id 0
> Ethernet II, Src: 42:be:ef:19:00:61 (42:be:ef:19:00:61), Dst: ASRockIn_37:78:72 (d0:50:99:37:78:72)
> Internet Protocol Version 4, Src: 146.66.155.66, Dst: 10.19.128.131
> User Datagram Protocol, Src Port: 27037, Dst Port: 63694
> Data (1233 bytes)
```

Slika 4.2 Primjer .pcap datoteke: mrežni promet snimljen tijekom igranja

4.3.4. Snimanje korisničkog unosa miša i tipkovnici

Programom Macro Recorder snimljene su korisničke kontrole i pohranjene kao *.mrf* datoteke. U ovome radu analizirat će se mrežni promet kojeg klijent šalje poslužitelju, te vidjeti kako žanr igre i vrsta kontrolera koja se koristi za igranje utječu na mrežni prometa. Promet u smjeru poslužitelj-klijent se sastoji samo od korisničkih naredbi tako da *.mrf* datoteke se neće analizirati.

4.3.5. Steam Stream Log

Prilikom svake korisničke sjednice Steam na poslužiteljskom računalu stvori datoteku *streaming_log.txt* (Slika 4.3). U njoj su sadržane informacije o nazivu igre, korištenoj rezoluciji, brzini kodiranja, vrsti kontrolera, vremenskoj oznaci (engl. *timestamp*) kada je igra igrana, prosječnom broju okvira u sekundi kao i mnoge druge informacije koje nisu korištene u ovom radu. Ove datoteke su služile kao provjera da su korištene ispravne postavke tijekom snimanja. Za svaku kombinaciju rezolucije, broja okvira i brzine kodiranja postoji pet različitih sjednica, međutim za tih pet sjednica pohranjena je samo

jedna *streaming_log* datoteka koja unutar sebe sadrži informacije o svih pet sjednica, tako da za jednu igru imamo ukupno 12 različitih *streaming_log* datoteka.

```
[2022-06-13 14:53:28] Changing record window: 00310636
[2022-06-13 14:53:28] Window title set to Assetto Corsa Launcher
[2022-06-13 14:53:28] >>> Starting desktop stream
[2022-06-13 14:53:28] CDesktopCaptureDWM: Reinitializing D3D for adapter 0xba76
[2022-06-13 14:53:28] Video adapter: NVIDIA GeForce RTX 3070, vendor ID: 0x10de, device ID: 0x2488
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop duplication enabled
[2022-06-13 14:53:28] >>> Switching video stream from GameOverlay_MovieStream_17372 to Desktop_MovieStream
[2022-06-13 14:53:28] "SessionStats"
{
        "ClientDeviceID"                "OnePlus AC2003"
        "ClientDeviceVersionID"         "Android 12"
        "GameNameID"            "Assetto Corsa"
        "appid"         "244210"
        "TimeSubmitted"         "1655124808"
        "ResolutionX"           "2560"
        "ResolutionY"           "1440"
        "CaptureDescriptionID"          "Game polled D3D11 NV12 + NVENC H264"
        "DecoderDescriptionID"          "Android texture hardware decoding"
        "BandwidthLimit"                "100000"
        "FramerateLimit"                "0"
        "Transport"             "1"
        "SlowGamePercent"               "2.80291342735290527"
        "SlowCapturePercent"            "0"
        "SlowConvertPercent"            "0"
        "SlowEncodePercent"             "0"
        "SlowNetworkPercent"            "31.6238155364990234"
        "SlowDecodePercent"             "0"
        "SlowDisplayPercent"            "1.26629924774169922"
        "AvgClientBitrate"              "78.2421493530273438"
        "StdDevClientBitrate"           "92.3472824096679688"
        "AvgServerBitrate"              "2163.302978515625"
        "StdDevServerBitrate"           "0"
        "AvgLinkBandwidth"              "100000.0078125"
        "AvgPingMS"             "115.107467651367188"
        "StdDevPingMS"          "180.618759155273438"
        "AvgCaptureMS"          "0.435276180505752563"
        "StdDevCaptureMS"               "0.190806582570075989"
        "AvgConvertMS"          "0.00332339480519294739"
        "StdDevConvertMS"               "0.00787152070552110672"
        "AvgEncodeMS"           "6.03176546096801758"
        "StdDevEncodeMS"                "1.53332650661468506"
        "AvgNetworkMS"          "70.5477676391601562"
        "StdDevNetworkMS"               "129.867141723632812"
        "AvgDecodeMS"           "1.59232783317565918"
        "StdDevDecodeMS"                "1.35641682147979736"
        "AvgDisplayMS"          "12.3623332977294922"
        "StdDevDisplayMS"               "15.169886589050293"
        "AvgFrameMS"            "140.088577270507812"
        "StdDevFrameMS"         "81.0608367919921875"
        "AvgFPS"                "61.1158332824707031"
        "StdDevFPS"             "22.0777111053466797"
        "BigPicture"            "1"
        "KeyboardMouseInput"            "1"
        "SteamControllerInput"          "0"
        "TouchControllerInput"          "1"
        "GameControllerInput"           "0"
        "XBox360ControllerInput"                "0"
        "XBoxOneControllerInput"                "0"
        "PS3ControllerInput"            "0"
        "PS4ControllerInput"            "0"
        "OtherControllerInput"          "0"
        "WasSpectating"         "0"
        "RemotePlayTogether"            "0"
}
[2022-06-13 14:53:28] >>> Capture method set to Desktop DWM NV12 + NVENC H264
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop access lost, reacquiring
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop duplication enabled
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop access lost, reacquiring
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop duplication enabled
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop access lost, reacquiring
[2022-06-13 14:53:28] CDesktopCaptureDWM: desktop duplication enabled
[2022-06-13 14:53:37] CDesktopCaptureDWM: GetWindowSurface() failed for window 00310636
[2022-06-13 14:53:37] Changing record window: 00000000
```

Slika 4.3 Primjer Steam streaming_log.txt datoteke

5. Analiza prikupljenih podataka

U ovome poglavlju su objašnjene pojedine prostorne i vremenske video metrike, te je analiziran utjecaj promjene pojedinog parametra na te metrike. Također je provedena analiza utjecaja parametara na mrežni promet, kao i kategorizacija igara prema mrežnim podatcima i vrijednostima video metrika.

5.1. Analiza video sadržaja

Za analizu video sadržaja izračunate su vremenske i prostorne metrike nad 1200 *.avi* datoteka, te su igre kategorizirane prema ovim metrikama. Također se proučava utjecaj promjene pojedinog parametra (brzine kodiranja, rezolucije i broja okvira u sekundi) na ove vrijednosti.

5.1.1. Analizirane video metrike

Kako bi mogli kategorizirati igre po njihovoj vizualnoj složenosti i dinamici, izračunate su vremenske i prostorne komponente snimljenih videozapisa. Prvi set metrika (PFIM i IBS) preuzet je iz rada Marka Claypool-a u kojem koristi intra-kodirane makroblokove za izračun prostorne i vremenske složenosti [30]. Drugi set metrika (SI i TI) preuzet je prema ITU-T preporuci P.910 (4/2008) [31]. Uz kategorizaciju igara, analizirat će se kako broj okvira u sekundi, rezolucija i brzina kodiranja utječu na pojedine video metrike.

5.1.1.1 PFIM (engl. Percentage of Forward/backward or Intra-coded Macroblocks)

PFIM je metrika za izračun dinamike kretnje unutar videa izražena u postotcima kodiranih makroblokova. Radi na pretpostavci da će promjene između susjednih okvira (engl. *frame*) biti kodirane u susjednim blokovima ili neovisno o susjednim blokovima, dok za video koji nema velike promjene scene može se preskočiti veliki dio kodiranja. Dobivena PFIM vrijednost je prosjek vrijednosti nad svim okvirima.

5.1.1.2 IBS (engl. Intra-coded Block Size)

IBS je metrika za izračun vizualne složenosti scene unutar videa. Ako je scena jednostavna onda nije potrebno kodirati veliki broj informacija u blok, te će veličina intra-kodiranog bloka biti mala, međutim ako je scena vizualno kompleksna onda će biti potrebno pohraniti više informacija te će veličina intra-kodiranog bloka biti velika. IBS se izražava kao prosjek vrijednosti izračunate za svaki okvir.

5.1.1.3 SI (engl. Spatial perceptual Information)

SI se koristi za identifikaciju piksela koji se najviše razlikuju od susjednih piksela, te identificirani pikseli predstavljaju rubove slike. Ako su poznati rubovi slike moguće je reducirati i filtrirati suvišne informacije unutar slike. Svaki se okvir unutar videa u trenutku n (F_n) prvo filtrira sa Sobel filterom [$Sobel(F_n)$], zatim se za svaki okvir izračuna standardna devijacija po pikselima (std_{space}). Ovim procesom dobije se vremenski slijed prostornih informacija scene. Najveća vrijednost u vremenskom slijedu (max_{time}) predstavlja sadržaj prostornih informacija scene. Ovaj proces se može predstaviti u obliku jednadžbe (1).

$$SI = maxtime\{stdspace[Sobel(Fn)]\} \tag{1}$$

5.1.1.4 TI (engl. Temporal perceptual Information)

TI se temelji na svojstvu razlike pokreta $M_n(i,j)$, što označava razliku između osvjetljenja piksela u vremenskom toku na istoj prostornoj poziciju. $M_n(i, j)$ kao funkcija vremena (n) definirana je kao (2).

$$Mn(i,j) = Fn(i,j) - Fn-1(i,j) \tag{2}$$

$F_n(i, j)$ predstavlja vrijednost osvijetljenosti piksela u *i*-tom retku i *j*-tom stupcu n-tog okvira u vremenu. TI se računa kao maksimum tijekom vremena (max_{time}) standardne devijacije po prostoru (std_{space}) od $M_n(i, j)$ nad svim *i* i *j*. Ovo je prikazano u formuli (3).

$$TI = maxtime\{stdspace[Mn(i,j)]\} \quad (3)$$

5.1.2. Prostorna i vremenska analiza: PFIM i IBS metrike

U ovim poglavljima će se analizirati zasebni utjecaji promjene brzine kodiranja, rezolucije i broja okvira na IBS/PFIM vrijednosti, tj. na vremensku i prostornu složenost videa. Analizirat će se kako položaj kamere i žanr igre utječe na IBS/PFIM vrijednosti.

Na Slici 5.1 vidimo raspodjelu igara na IBS/PFIM grafu kada su parametri postavljeni na najveće vrijednosti (20 Mbit/s, 1080p, 60 fps). Možemo vidjeti da igre iz prvog i trećeg lica uglavnom imaju visoke PFIM vrijednost i niske IBS vrijednosti, dok za razliku od njih igre koje imaju pogled odozgo (*Company of Heroes 2*, *Divinity Original Sin*, *Shadow Tactics*) imaju visoke IBS i niske PFIM vrijednosti. Igre *Endless Space 2*, *Ring of Pain* i *Dota 2* imaju niske IBS i niske PFIM vrijednosti. Sve tri igre koje za obje komponente imaju niske vrijednosti su relativno vizualno jednostavne i spore dinamike igranja što bi moglo objasniti ove rezultate. Trkaće igre (*Dirt 5* i *Burnout Paradise*), te igra *Grim Dawn* nalaze se blizu sredine grafa, što ukazuje da imaju ravnotežu između vizualne složenosti i dinamike igranja. *Batman Arkham Knight*, *Doom*, *Alan Wake* i *Prey* su pri samome vrhu PFIM vrijednosti, a ujedno imaju najniže IBS vrijednosti. Razlog tome bi mogao biti to da sve od ovih igara imaju sličnu mračnu paletu boja i relativno brzu dinamiku igranja. Ne postoji igra u ovome testiranju koja ima jako visoke i PFIM i IBS vrijednosti.

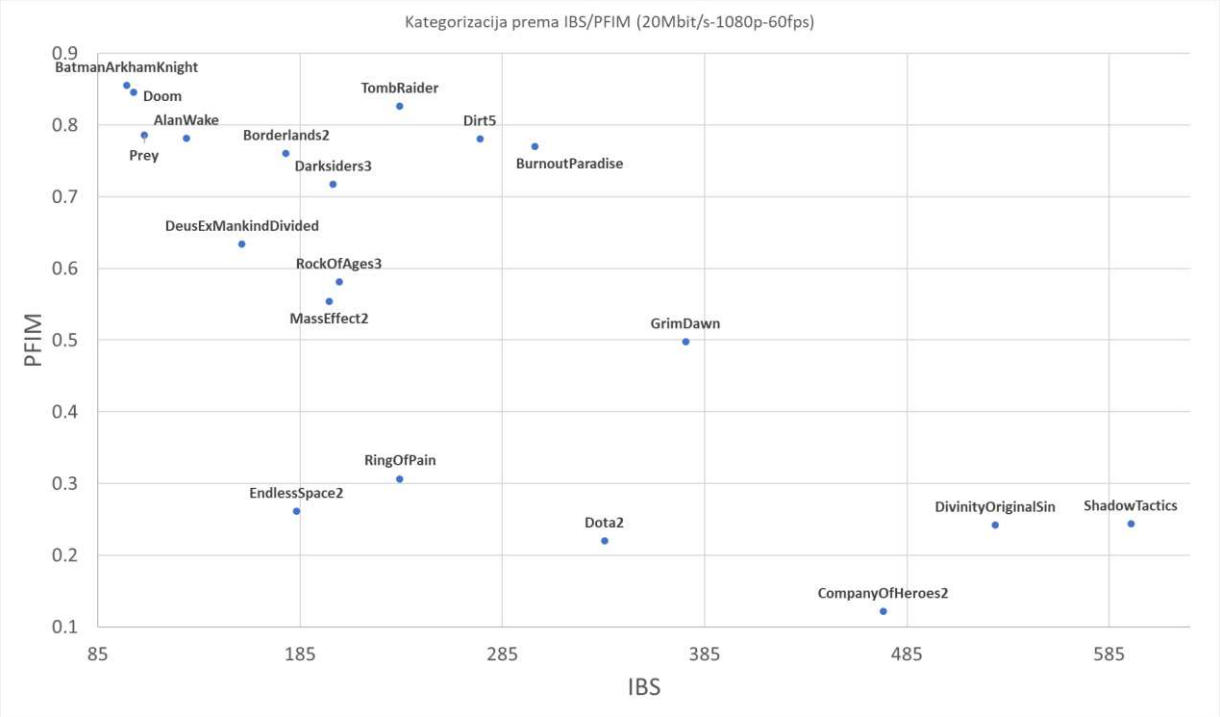

Slika 5.1 Kategorizacije igara prema IBS/PFIM vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps

U cilju provjere dobivenih rezultata napravljena je ista vrsta prikaza podataka (Slika 5.2), ali jedina razlika je da su umjesto najvećih vrijednosti parametara uzete najmanje vrijednosti (5 Mbit/s, 720p, 30 fps). Vidimo da dobijemo jako slične rezultate, najveća razlika je za igru *Mass Effect 2* kojoj IBS vrijednost je ostala na sličnoj poziciji, no PFIM vrijednost je značajno pala. Razlike za ostale igre su relativno male te vjerojatno nastaju zbog varijacija u igranju.

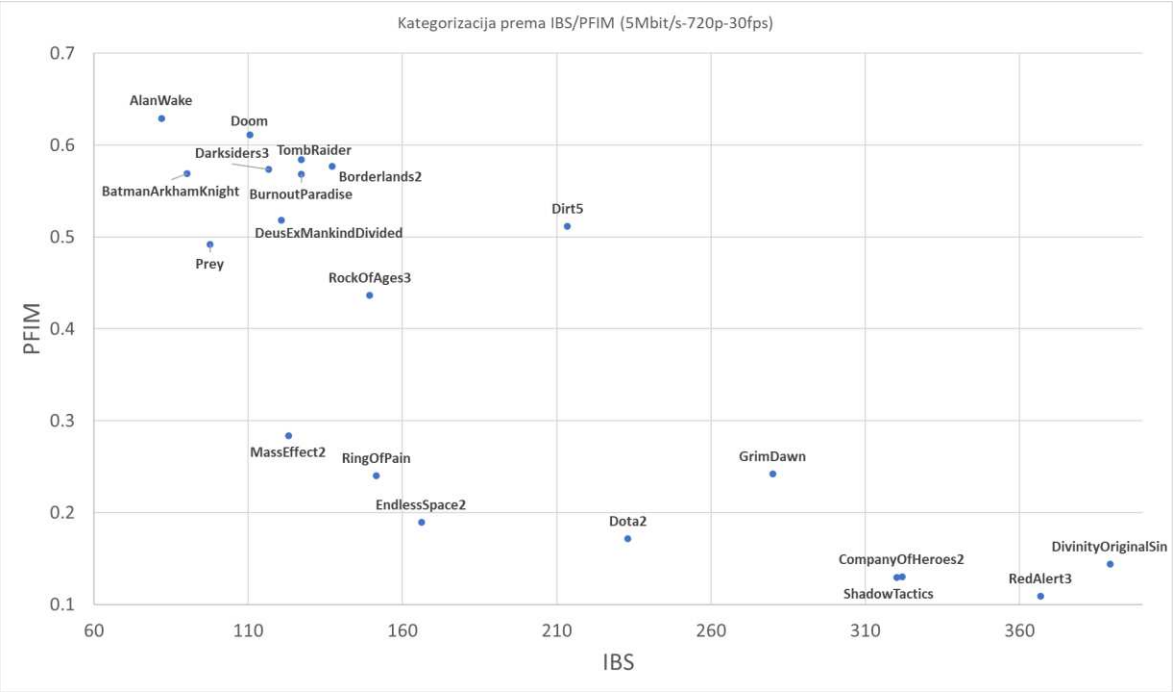

Slika 5.2 Kategorizacije igara prema IBS/PFIM vrijednostima za parametre postavljene na 5 Mbit/s-720p-30fps

5.1.2.1 Način prikaza rezultata

Nad igrom *Alan Wake* provedena je analiza može li se uzeti prosjek snimanja na razini jedne igre. Pošto svaka kombinacija parametara unutar jedne igre ima 5 različitih snimanja, za prikazivanje rezultata uzeta je prosječna vrijednost svih 5 snimanja. Na Slici 5.3 vidimo prikazanih svih 5 vrijednosti za igru *Alan Wake* pri kombinaciji parametara 5 Mbit/s-720p-30 fps. Uzimanje prosjeka svih snimanja ne bi trebalo značajno utjecati na rezultate. Za analizu rezultata uzet ćemo primjere za 3 igre koje spadaju u različite kategorije na IBS/PFIM grafu: jedna igra s visokom PFIM i niskom IBS vrijednosti, jedna s visokom IBS i niskom PFIM vrijednosti, te jedna igra koja ima uravnotežene PFIM i IBS vrijednosti.

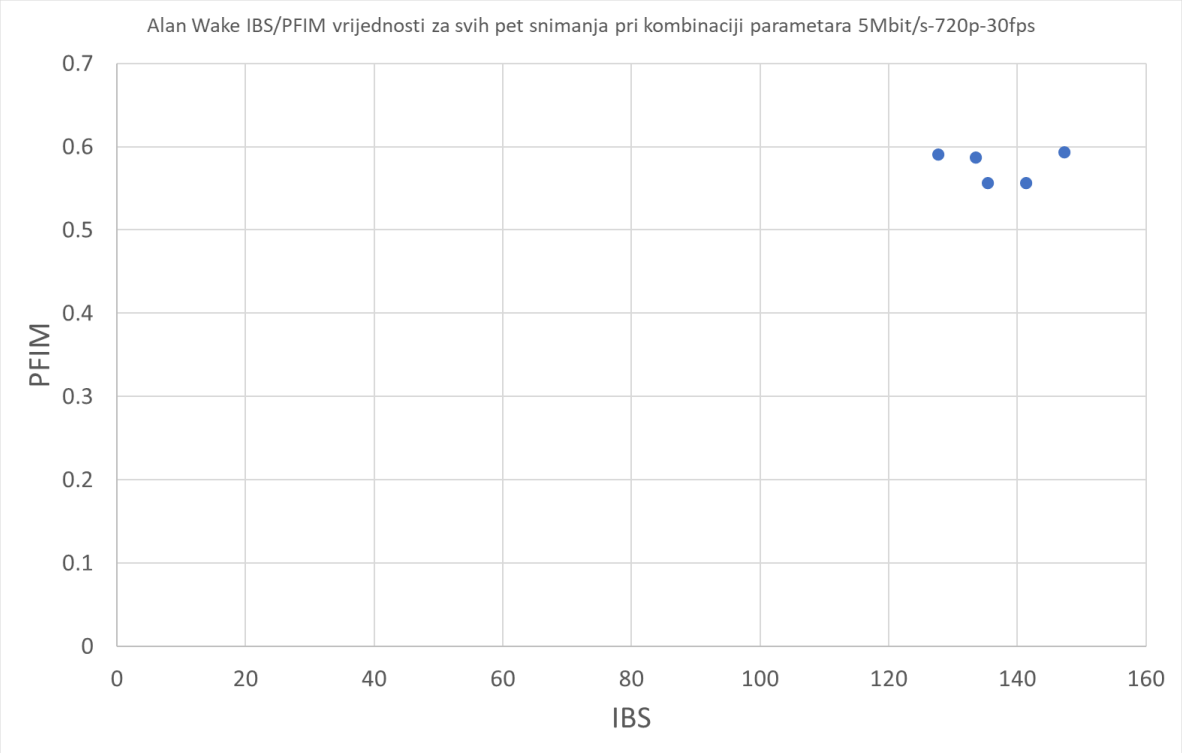

Slika 5.3 IBS/PFIM vrijednost igre Alan Wake pri kombinaciji parametara 5 Mbit/s-720p-60 fps za svih pet snimanja unutar kombinacije

5.1.2.2 Utjecaj promjene brzine kodiranja na PFIM i IBS metrike

U ovome poglavlju će se analizirati kako brzina kodiranja utječe na PFIM i IBS metrike. Za analizu ćemo pogledati dva slučaja: 1) kada je parametar rezolucije na 720p i broj okvira na 30 fps i 2) kada je rezolucija 1080p i broj okvira 60 fps. Pri tako postavljenim parametrima rezolucije i broja okvira u sekundi promatrat ćemo promjene kada se brzina kodiranja mijenja s 5 Mbit/s na 10 Mbit/s i 20 Mbit/s. Prve tri igre koje su odabrane za prikaz podataka su *Alan Wake* (visoka PFIM vrijednost), *Shadow Tactics* (visoka IBS vrijednost) i *Dota 2* (niska IBS i PFIM vrijednost). Na Slici 5.4 rezolucija je postavljena na 720p i broj okvira u sekundi na 30 fps. Pri tim parametrima ne može se izvući neki zaključak vezan uz utjecaj brzine kodiranja na IBS/PFIM vrijednosti. Na prvi pogled izgleda kako da je IBS vrijednost veća što je brzina kodiranja veća, međutim postoji puno primjera gdje je IBS vrijednost veća za manje brzine kodiranja. Slika 5.5 prikazuje IBS/PFIM vrijednosti za igre *Deus Ex Mankind Divided* (visoke PFIM, niske IBS vrijednosti), *Endless Space* (uravnotežene PFIM i IBS vrijednosti), *Red Alert 3* (visoke IBS, niske PFIM vrijednosti) pri parametrima postavljenim kao na slici 5.4. Ovdje su IBS

vrijednost veće za manje brzine kodiranja. Na temelju rezultata ne može se izvući neki jasan zaključak o utjecaju brzine kodiranja na PFIM/IBS vrijednosti.

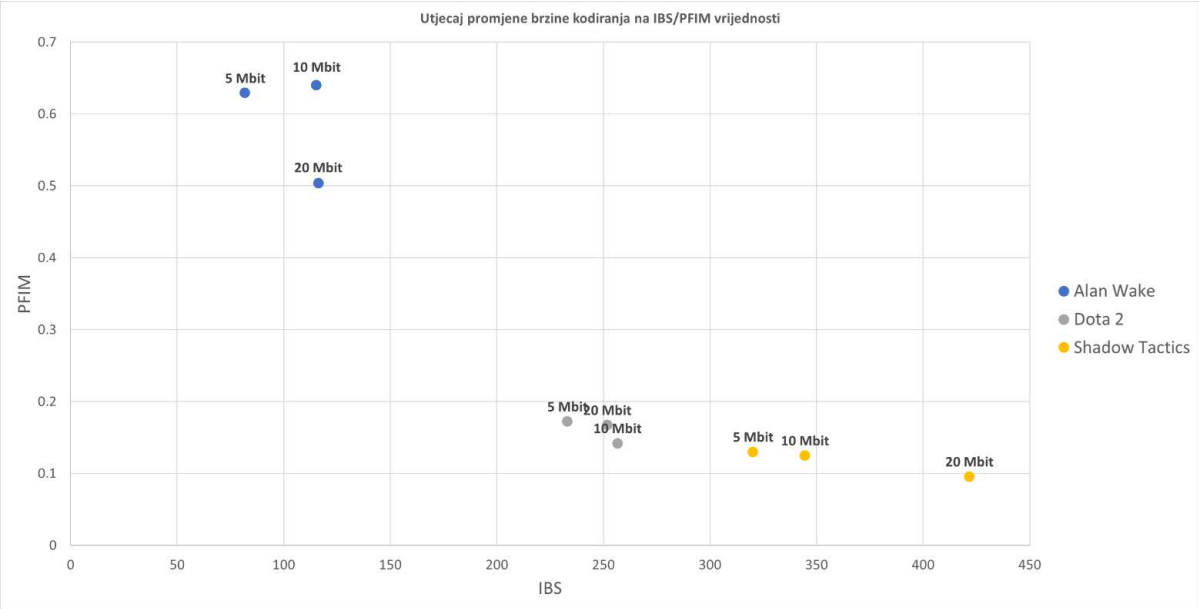

Slika 5.4 IBS/PFIM vrijednosti za igre Alan Wake, Dota 2 i Shadow Tactics pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps

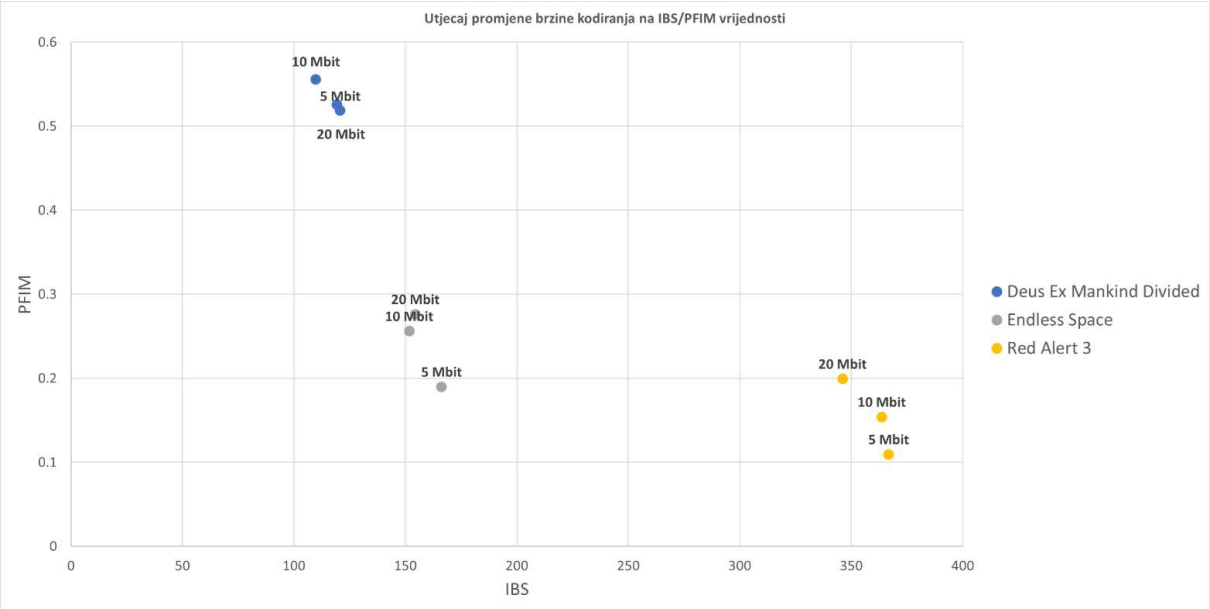

Slika 5.5 IBS/PFIM vrijednosti za igre Deus Ex Mankind Divided, Endless Space i Red Alert 3 pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps

Slika 5.6 prikazuje IBS/PFIM vrijednosti za igre *Alan Wake*, *Dota 2* i *Shadow Tactics* pri parametrima 1080p i 60 fps. I ovdje se može uočiti da brzina kodiranja nema neki značajniji utjecaj na PFIM ni na IBS komponentu. Iako nije izmjeren utjecaj brzine

kodiranja na IBS/PFIM komponente, iz subjektivne analize video uradaka, može se uočiti puno bolja kvaliteta slike (manje kompresijskih artefakata) pri većim brzinama kodiranja.

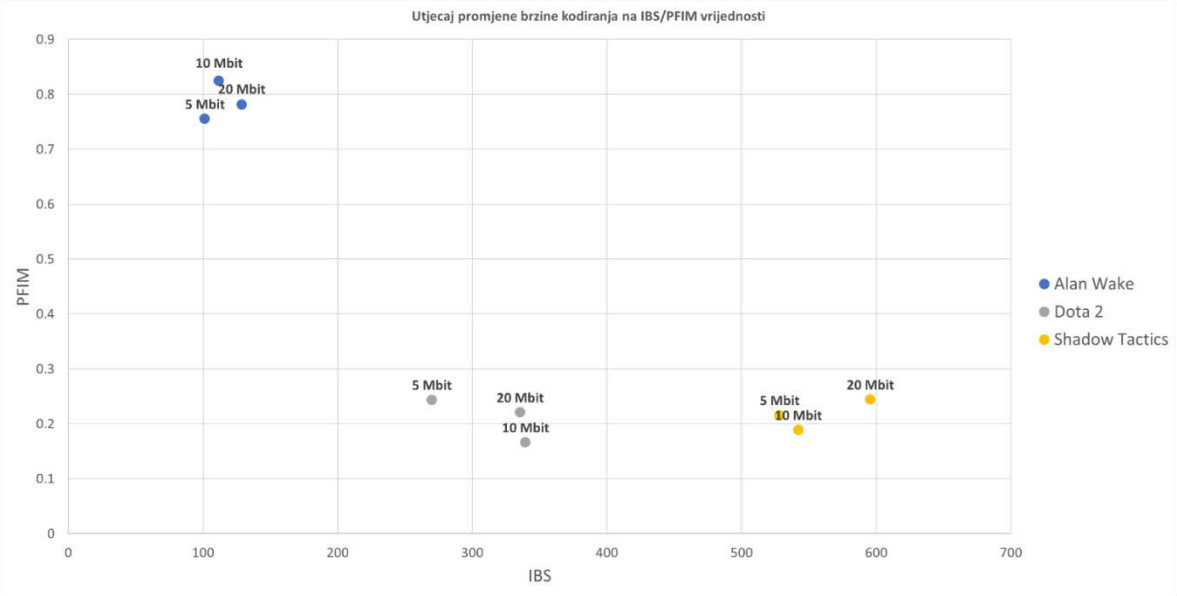

Slika 5.6 IBS/PFIM vrijednosti za igre Alan Wake, Dota 2 i Shadow Tactics pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 1080p-60 fps

5.1.2.3 Utjecaj promjene rezolucije na PFIM i IBS vrijednosti

Za analizu utjecaja promjene rezolucije na IBS/PFIM vrijednosti pogledat ćemo dva slučaja: 1) kada je parametar brzine kodiranja postavljen na 20 Mbit/s i broj okvira na 30 fps i 2) kada su parametri postavljeni na 5 Mbit/s i 30 fps.

Graf na slici 5.7 prikazuje situaciju kada je brzina kodiranja postavljena na 20 Mbit/s i broj okvira na 30 fps. Igre koje smo razmotrili su: *Dirt 5* (uravnotežene IBS i PFIM vrijednosti), *Batman Arkham Knight* (visoke PFIM vrijednosti, niske IBS vrijednosti) i *Company of Heroes* (visoka IBS, niska PFIM vrijednost). Odmah se može primijetiti da povećanjem rezolucije IBS vrijednost poraste. Najmanja promjena je za igru Di*rt 5* gdje je IBS vrijednost na rezoluciji 720p iznosi 238, a na rezoluciji 1080p IBS je vrijednosti 254, što je povećanje za oko 7 %. Povećanje IBS vrijednosti za *Batman Arkham Knight* u ovome slučaju iznosi 25 %, dok povećanje IBS vrijednosti za *Company Of Heroes 2* je 43 %. Prosječno povećanje IBS vrijednosti za sve igre pri ovim parametrima je bilo oko 28 %.

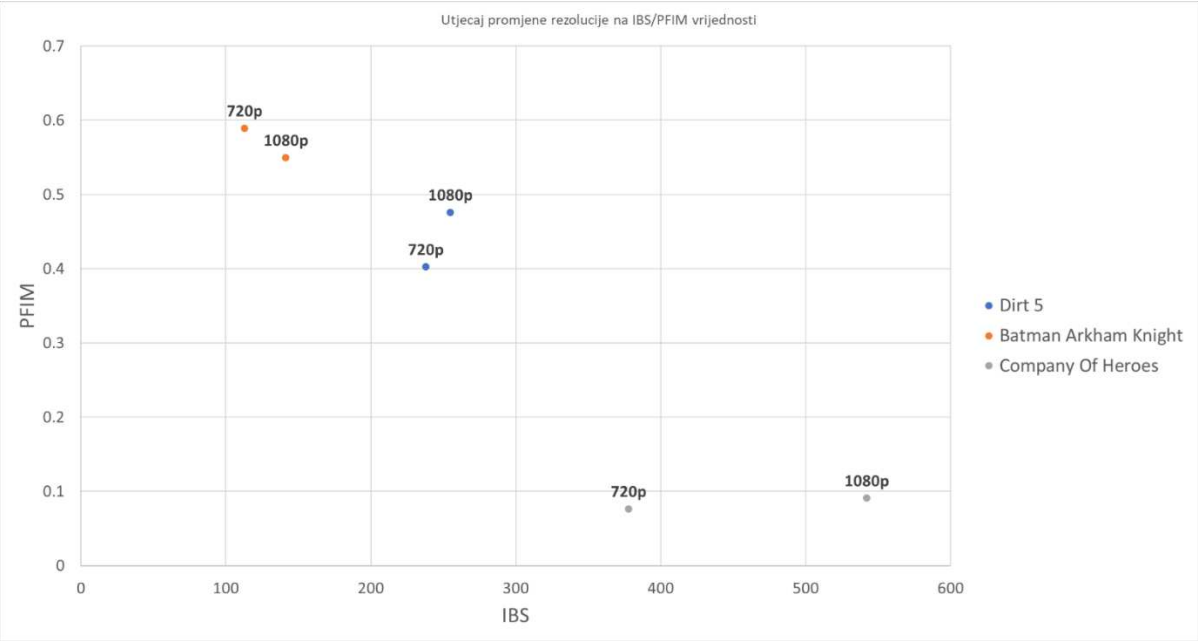

Slika 5.7 IBS/PFIM vrijednosti za igre Burnout Paradise, Batman Arkham Knight i Company of Heroes pri različitim rezolucijama i ostalim parametrima postavljenim na 20 Mbit/s-30 fps

U drugom slučaju (Slika 5.8) analiziramo utjecaj promjene rezolucije na igrama *Doom* (visoka PFIM vrijednost, niska IBS), *Ring of Pain* (niska IBS i PFIM vrijednost) i *Shadow Tactics* (visoka IBS, niska PFIM vrijednost). Brzina kodiranja je postavljena na 5 Mbit/s i broj okvira u sekundi na 30 fps. U ovome primjeru također vidimo povećanje IBS vrijednosti, *Doom* za 4.3 %, *Ring of Pain* 21 % *i Shadow Tactics* 46 %. Prosječno povećanje IBS vrijednosti za sve igre je 23 %. Također je zanimljivo da najveća povećanja za IBS vrijednosti su za igre koje po kategorizaciji imaju veliku IBS i nisku PFIM vrijednost. Igre s jako visokom PFIM vrijednošću su obično među onima koje dobiju najmanje povećanje IBS vrijednosti. Trebalo bi također spomenuti utjecaj rezolucije na PFIM vrijednost, u velikom broju slučajeva PFIM se smanji za nekoliko postotaka. Promjena nije drastična kao kod IBS vrijednosti, ali je svejedno značajna. U slučaju sa slike 5.7 prosječno smanjenje za sve igre iznosi 9.5 %, dok u slučaju sa slike 5.8 prosječno smanjene iznosi 7.5 %. No taj gubitak ne čini se povezan sa žanrom igre, već izgleda nasumičan, jer se pojavi na različitim igrama za različite parametre. Postoji velika šansa da je nastao zbog različitih vrsta igranja, no svejedno ga treba spomenuti.

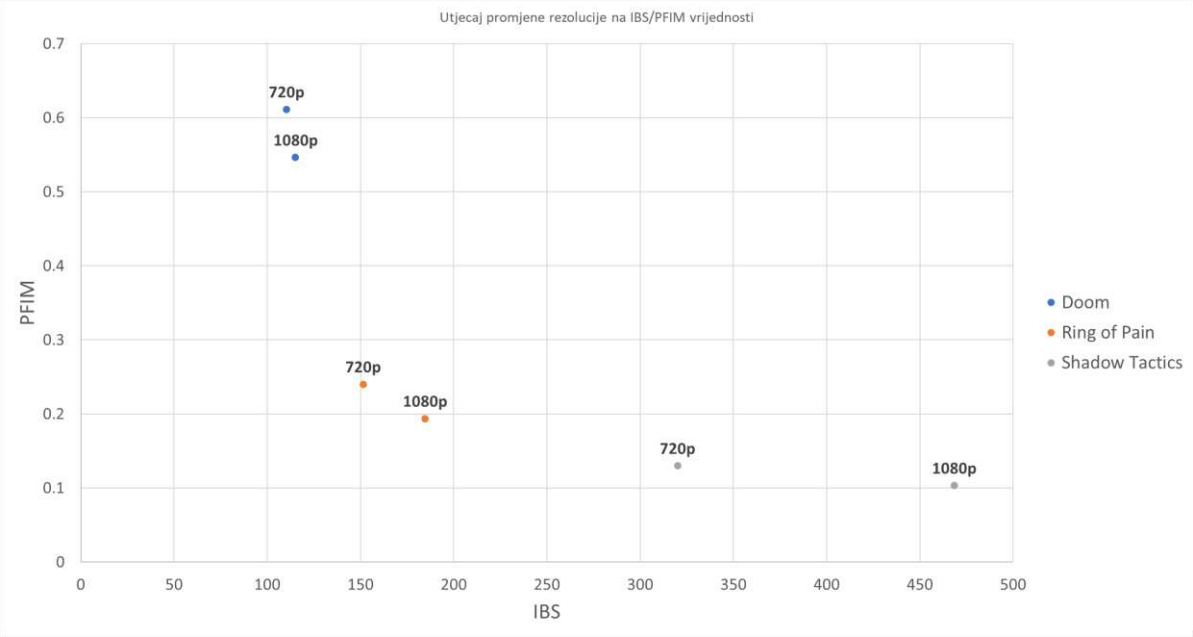

Slika 5.8 IBS/PFIM vrijednosti za igre Doom, Ring of Pain i Shadow Tactics pri različitim rezolucijama i ostalim parametrima postavljenim na 5 Mbit/s-30 fps

5.1.2.4 Utjecaj promjene broja okvira u sekundi na PFIM i IBS vrijednosti

U ovome poglavlju ćemo analizirati utjecaj broja okvira u sekundi na IBS/PFIM vrijednosti. Na slici 5.9 vidimo prikazan IBS/PFIM graf za različit broj okvira kada je brzina kodiranja postavljena na 20 Mbit/s i rezolucija na 720p. Na grafu vidimo vrijednosti za igre *Tomb Raider* (visoka PFIM, niska IBS vrijednost), *Company of Heroes 2* (visoka IBS, niska PFIM vrijednost) i *Endless Space* (uravnotežene IBS i PFIM vrijednosti). Odmah možemo uočiti da IBS vrijednosti ostaju približno iste za različit broj okvira u sekundi, dok se PFIM vrijednosti puno više mijenjaju. Najuočljivija promjena je za igru *Tomb Raider*, koja inače ima visoki PFIM i niski IBS, PFIM naraste s 0.6 (30 fps) na 0.93 (60 fps), što je povećanje od 54 %. Iako povećanje PFIM vrijednosti za strateške igre na prvi pogled ne izgleda veliko (jer su relativno niske vrijednosti za 30 fps i 60 fps), one su u postotcima najviše rasle. Primjer rasta je *Company of Heroes 2* gdje je PFIM vrijednost na 30 fps bila 0.077, a na 60 fps 0.14, što predstavlja rast od 89 %. Postoje slučajevi kao i za *Endless Space* gdje promjena broj okvira nije imala skoro nikakav utjecaj na PFIM vrijednost. Također treba imati na umu da je PFIM vrijednost izražena u postotcima, što znači da PFIM nikad ne može prijeći 1, stoga igre koje općenito imaju velike PFIM vrijednosti (vrijednosti veće od 0.5) nikada neće moći udvostručiti svoju PFIM vrijednost.

Prosječni rast PFIM vrijednosti kada je broj okvira povećan s 30 fps na 60 fps u ovome slučaju je iznosila 50 %.

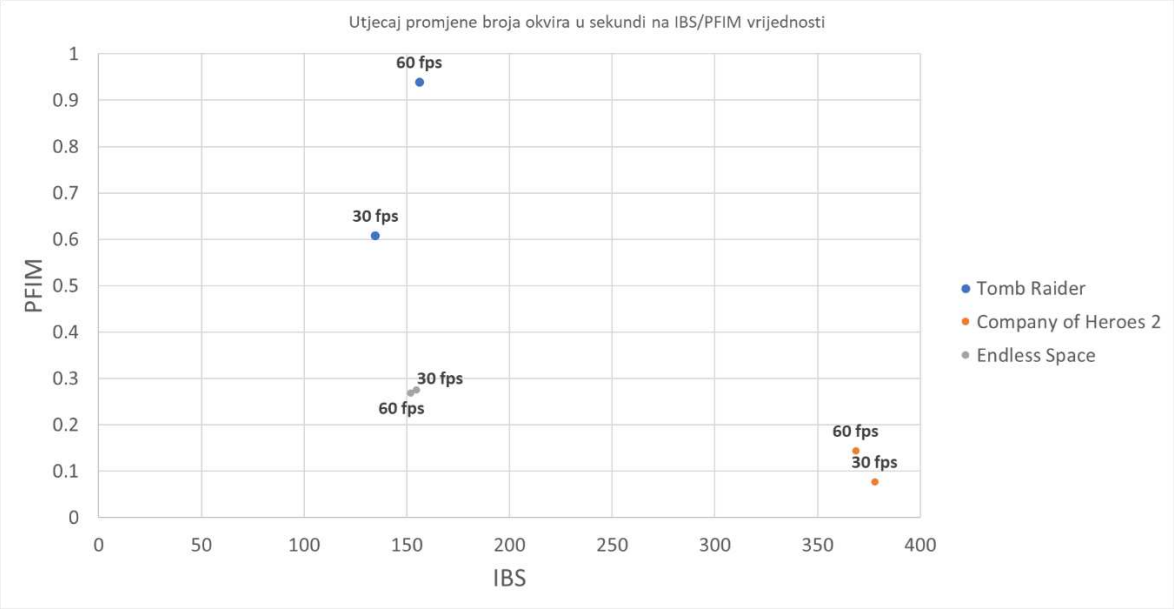

Slika 5.9 IBS/PFIM vrijednosti za igre Tomb Raider, Company of Heroes 2 i Endless Space pri različitim brojevima okvira i ostalim parametrima postavljenim na 20 Mbit/s-720p

Ako promijenimo rezoluciju na 1080p i spustimo brzinu kodiranja na 10 Mbit/s kao što je učinjeno na grafu sa slike 5.10, opet dobivamo skoro identične rezultate. Na ovom grafu su prikazane vrijednosti za igre *Darksiders 3* (visoka PFIM, niska IBS vrijednost), *Shadow Tactics* (visoka IBS, niska PFIM vrijednost) i *Ring of Pain* (uravnotežene IBS i PFIM vrijednosti). Na IBS vrijednosti opet promjena broja okvira ne utječe, međutim na PFIM vrijednosti utječe značajno. Slično kako je promjena rezolucije najviše utjecala na igre koje imaju visoku IBS vrijednost i nisku PFIM, tako promjena broja okvira u sekundi najviše utječe na igre koje imaju nisku IBS i visoku PFIM vrijednost.

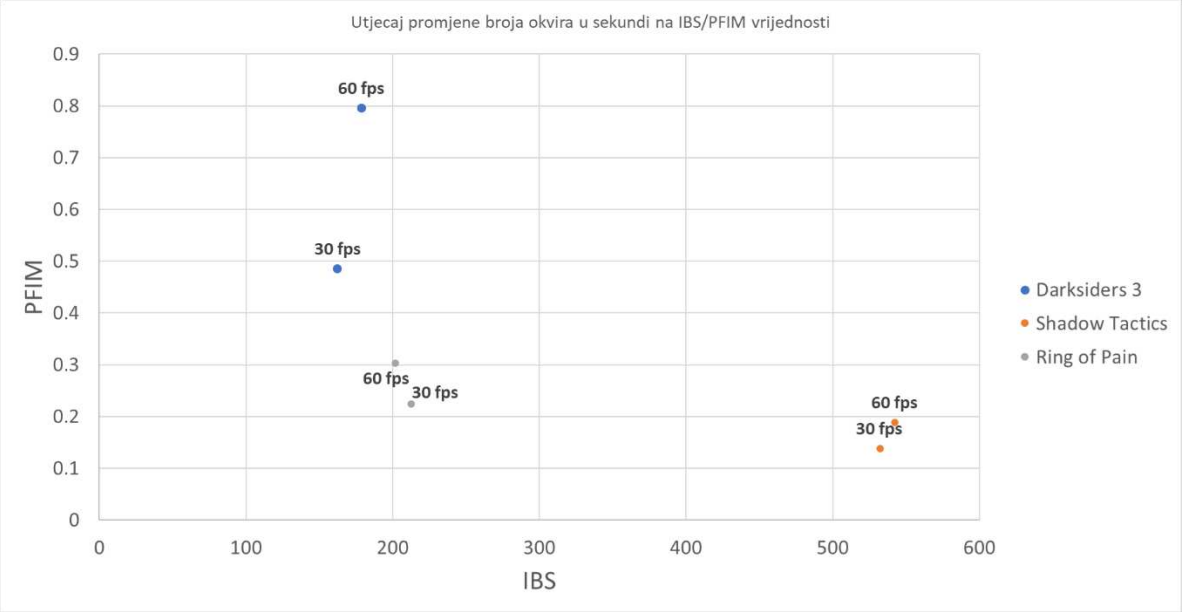

Slika 5.10 IBS/PFIM vrijednosti za igre Darksiders 3, Shadow Tactics i Ring of Pain pri različitim brojevima okvira i ostalim parametrima postavljenim na 10Mbit/s-1080p

5.1.3. Prostorna i vremenska analiza: SI i TI metrike

Slično kako je odrađena kategorizacija igara prema IBS/PFIM vrijednostima, tako ćemo odraditi i podjelu prema SI/TI vrijednostima. Parametri su se također postavili na najvišu kombinaciju (20 Mbit/s-1080p-60 fps) i na najnižu kombinaciju (5 Mbit/s-720p-30 fps), uzet je prosjek 5 snimanja svake igre za dane kombinacije, te su se izradili grafovi. Za SI/TI je preporučeno uzeti maksimalne izračunate vrijednosti, a ne prosjek izračunatih vrijednosti za svaki okvir unutar videa. To predstavlja problem zato što bi prije početka snimanja, igre bile zaustavljene, te kad bi krenulo snimanje, nastavilo se igranje iz izbornika. Taj prijelaz iz izbornika u igranje može znatno utjecati na maksimalne SI/TI vrijednosti jer se unutar dva okvira potpuno promjeni scena, te igra koja je inače dosta spora ili vizualno jednostavna će dobiti veliku maksimalnu SI/TI vrijednost samo zbog jedne promjene.

Na slici 5.11 je prikazan graf prosječnih SI/TI za sve igre pri kombinaciji parametara 20 Mbit/s-1080p-60 fps. Prvo što se može primijetiti da nema ekstrema kao što je bilo za IBS/PFIM, tj. nema igara koje imaju iznimno visok TI i nizak SI, ili obrnuto. Igre su puno bliže jedna drugoj, ali svejedno igre iz trećeg i prvog lica naginju na viši TI i niži SI, dok igre koje imaju pogled odozgo imaju veći SI i niži TI. Igra *Dirt 5* je iznimka na ovome grafu jer ima visoke SI i TI vrijednosti.

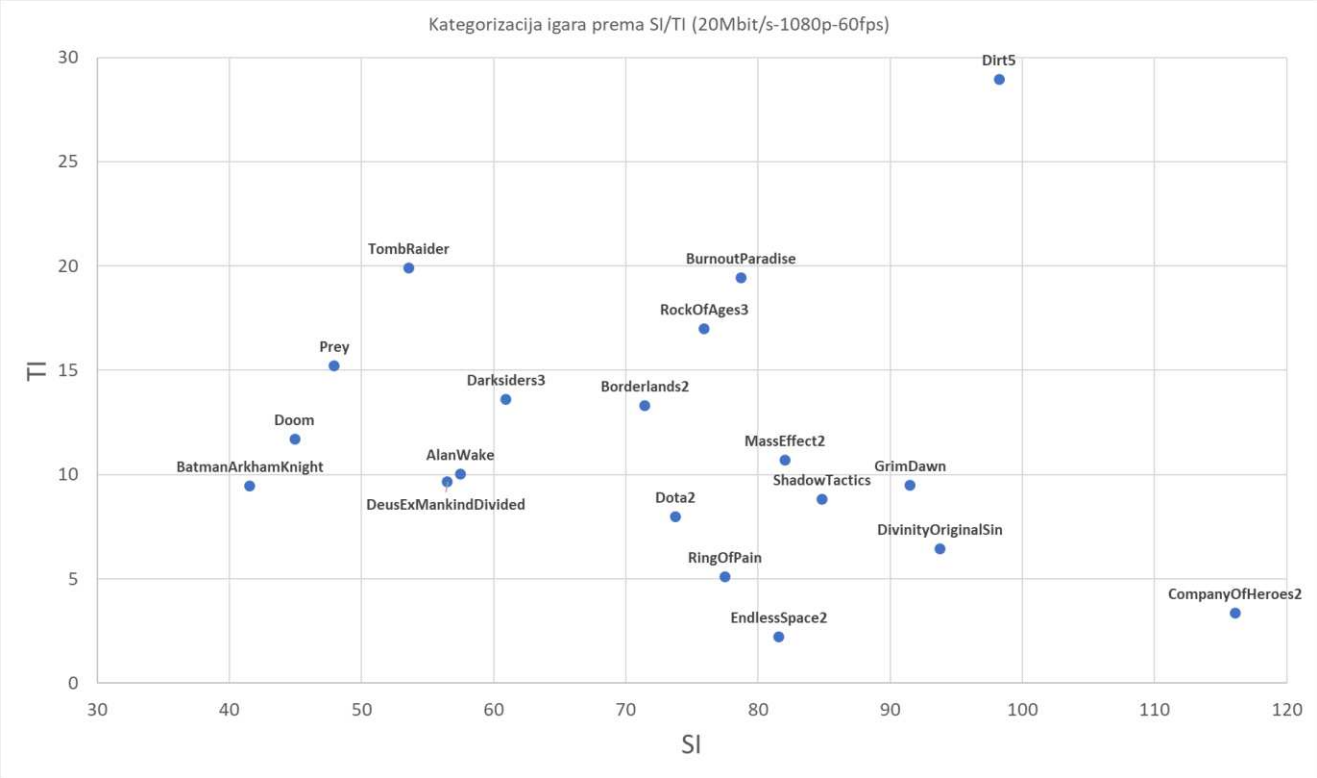

Slika 5.11 Kategorizacije igara prema SI/TI (prosjek) vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps

Slika 5.12 predstavlja kategorizaciju s istim parametrima kao i na slici 5.11, jedina razlika je što su uzete maksimalne SI/TI vrijednosti, umjesto prosječnih. Postoji par problema s ovim grafom, neke igre su sličnih vrijednosti, a potpuno različitih žanrova i načina igranja. Primjer toga su igra *Ring of Pain* (igra vrlo jednostavne prezentacije i spore dinamike igranja) koja ima približno iste vrijednosti kao i *Borderlands 2* (pucačina iz prvog lica), ili *Alan Wake* i *Dota 2* koji imaju skoro identične vrijednosti. Zbog ovoga razloga ubuduće će se koristiti prosječna SI/TI vrijednost, umjesto maksimalne.

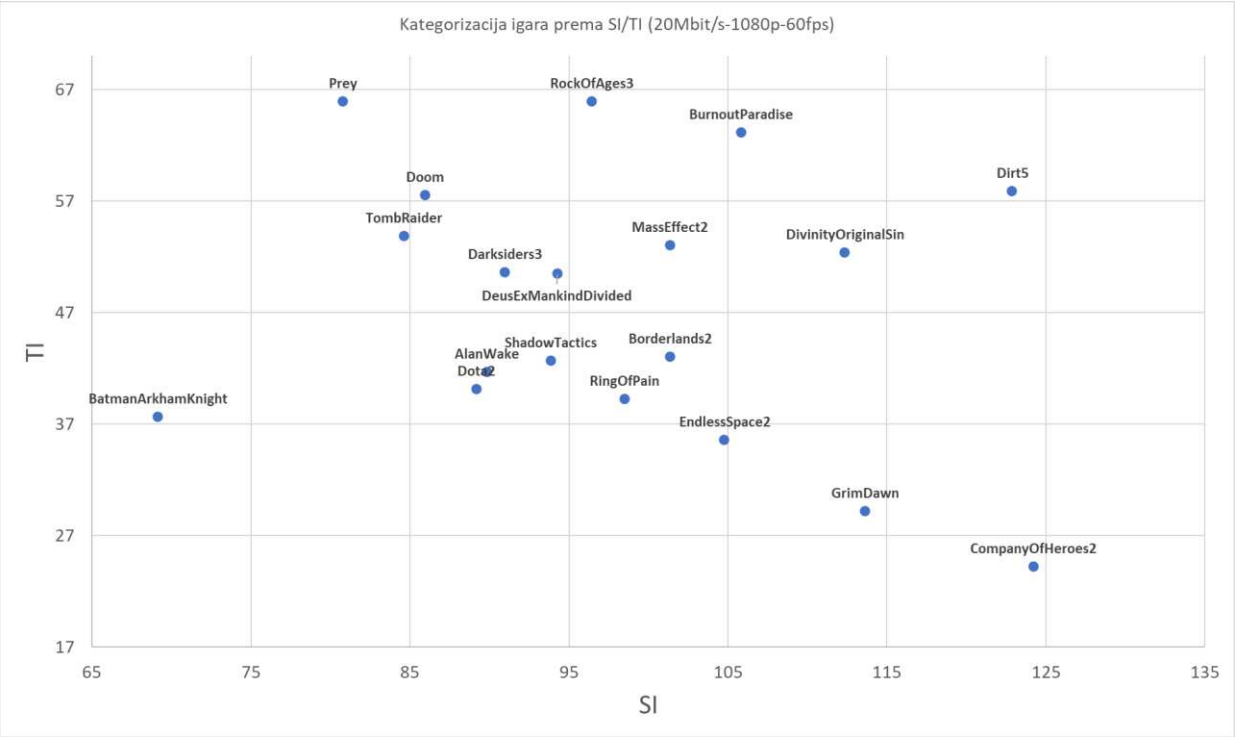

Slika 5.12 Kategorizacije igara prema SI/TI (maksimum) vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps

Ako postavimo parametre na najniže vrijednosti (5 Mbit/s-720p-30 fps), dobivamo skoro jednaku podjelu igara kao i za parametre na najvećim vrijednostima. Ova podjela je prikazana na slici 5.13. Na slici 5.14 je prikazan isti graf kao i na slici 5.13, jedina razlika je što su uzete maksimalne SI/TI vrijednosti umjesto prosječnih. Opet su vidljive neke nelogičnosti kao da *Company of Heroes* (strateška igra) ima puno veću maksimalnu TI vrijednost nego trkaće igre ili pucačine.

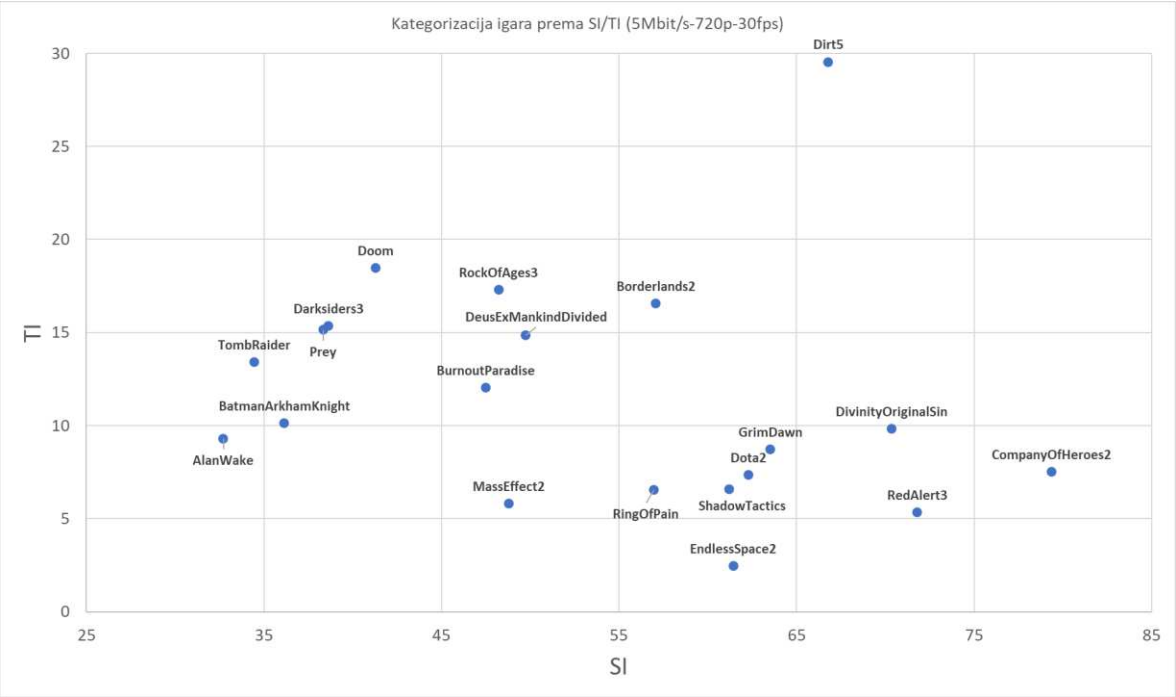

Slika 5.13 Kategorizacije igara prema SI/TI (prosjek) vrijednostima za parametre postavljene na 5 Mbit/s-720p-30 fps

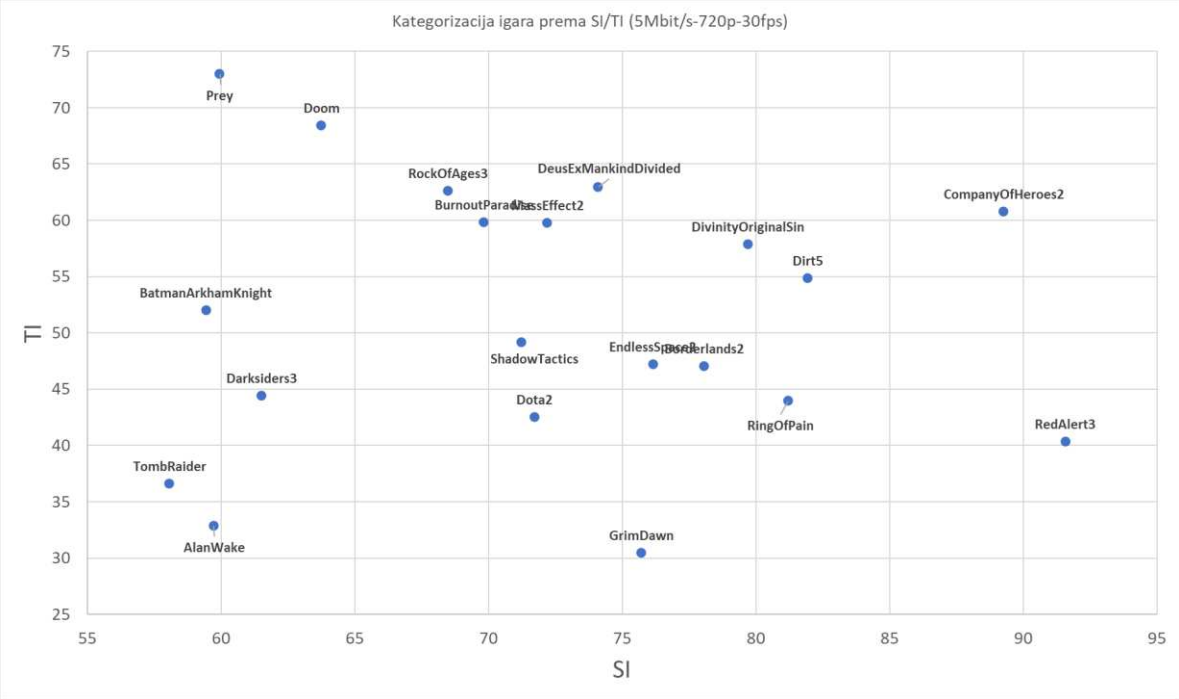

Slika 5.14 Kategorizacije igara prema SI/TI (maksimalne) vrijednostima za parametre postavljene na 5 Mbit/s-720p-30 fps

5.1.3.1 Utjecaj promjene brzine kodiranja na SI i TI metrike

Slično kao i za PFIM/IBS analizu, ovdje će se pogledati utječe li brzina kodiranja na SI/TI vrijednosti. Za analizu ćemo prikazati rezultate za 4 igre: *Dirt 5* (visoke SI i TI vrijednosti), *Darksiders 3* (SI i TI vrijednosti prosječnih veličina), *Endless Space 2* (visoke SI i niske TI vrijednosti) i *Batman Arkham Knight* (niske SI i niske TI vrijednosti). Ovdje prikazujemo rezultate za 4 igre, za razliku od PFIM/IBS analize gdje smo analizirali po 3 igre. To je zato što su igre puno raspršenije prema SI/TI kategorizaciji, nego što je to bio slučaj za PFIM/IBS kategorizaciju. Graf na slici 5.15 prikazuje SI/TI vrijednosti kada su parametri rezolucije i broja okvira postavljeni na 1080p i 60 fps, a brzinu kodiranja mijenjamo između 5 Mbit/s, 10 Mbit/s i 20 Mbit/s. Dolazi se do sličnog zaključka kao i u analizi brzine kodiranja u vezi s PFIM/IBS, a to je da brzina kodiranja značajno ne utječe na video komponente.

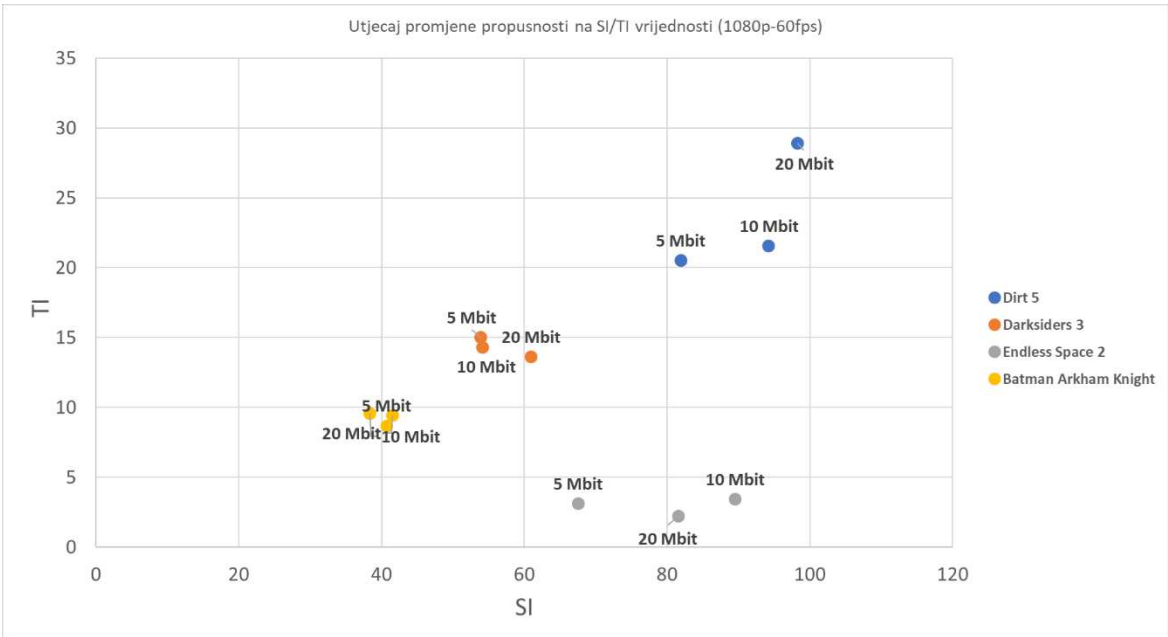

Slika 5.15 SI/TI vrijednosti za igre Dirt 5, Darksiders 3, Endless Space 2 i Batman Arkham Knight pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 1080p-60 fps

Na slici 5.16 prikazana je ista vrsta grafa kao i na prijašnjoj slici, jedina razlika je promjena rezolucije na 720p i broja okvira na 30 fps. I ovdje vidimo slične rezultate. Igra *Batman Arkham Knight* ima gotovo jednake rezultate za sve 3 brzine kodiranja, najviše varijacije na oba grafa pokazuje *Dirt 5*, ali iz svih dostupnih podataka ne može se izvući neki zaključak o utjecaju brzine kodiranja na SI/TI komponente.

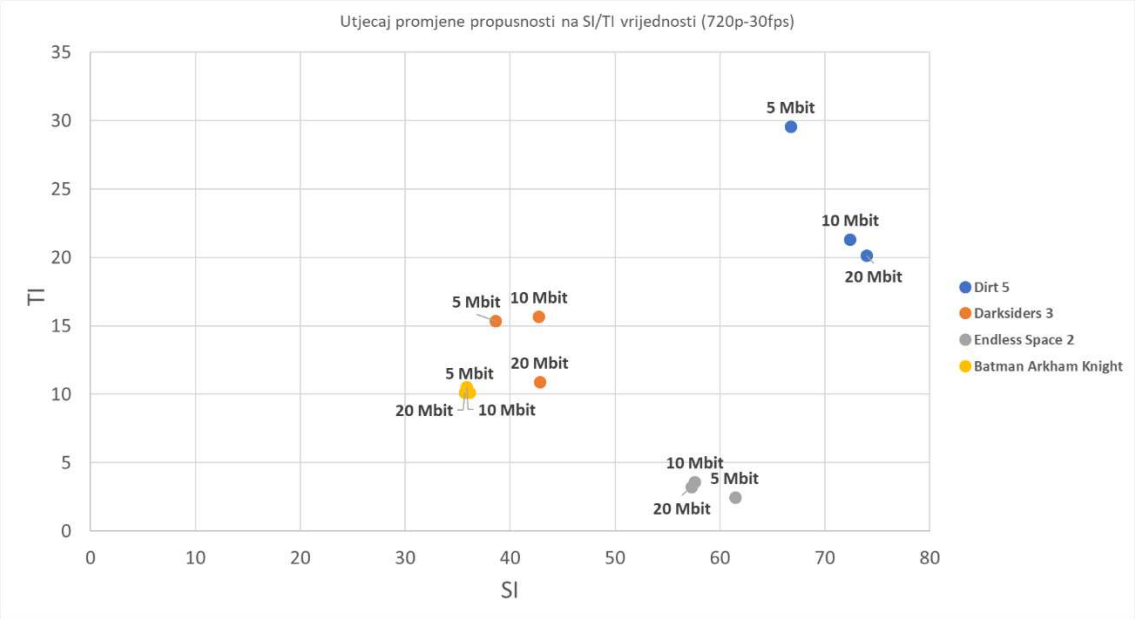

Slika 5.16 SI/TI vrijednosti za igre Dirt 5, Darksiders 3, Endless Space 2 i Batman Arkham Knight pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps

5.1.3.2 Utjecaj promjene rezolucije na SI i TI metrike

Tijekom analize utjecaja rezolucije na PFIM/IBS metrike, uočeno je da povećanjem rezolucije bi došlo do povećanja IBS komponente i možda blagog smanjenja PFIM komponente. Situacija za SI/TI komponente je malo drugačije, izgleda da povećanjem rezolucije dolazi do povećanja i SI i TI vrijednosti.

Na slici 5.17 prikazan je graf u slučaju kada mijenjamo rezoluciju, a brzina kodiranja je postavljena na 20 Mbit/s i broj okvira na 30 fps. Igre odabrane za demonstraciju su: *Deus Ex Mankind Divided* (visoke TI, niske SI vrijednosti), *Ring of Pain* (niska TI i niska SI vrijednost), *Company of Heroes 2* (niske TI, visoke SI vrijednosti) i *Prey* (srednje visoka TI vrijednost i niska SI vrijednost). Za prijelaz rezolucije sa 720p na 1080p igra Prey ima najmanje povećanje SI komponente (23 posto), dok *Company of Heroes 2* ima najveće povećanje (56 %). Slično kao i kod IBS/PFIM analize, igre koje su imale visoku SI komponentu, ujedno su dobili i najveće povećanje. Prosječno povećanje SI komponente za sve igre pri ovim parametrima je 30 %. Povećanje TI komponente možda nije očekivano s povećanjem rezolucije, ali TI radi tako da uspoređuje piksele na istim pozicijama u susjednim okvirima, i ako je veća rezolucija onda ima više piksela za usporediti i šansa je da će biti veća razlika nego kada je manje piksela. Prosječno povećanje TI vrijednosti s povećanjem rezolucije pri ovim parametrima je 24 %.

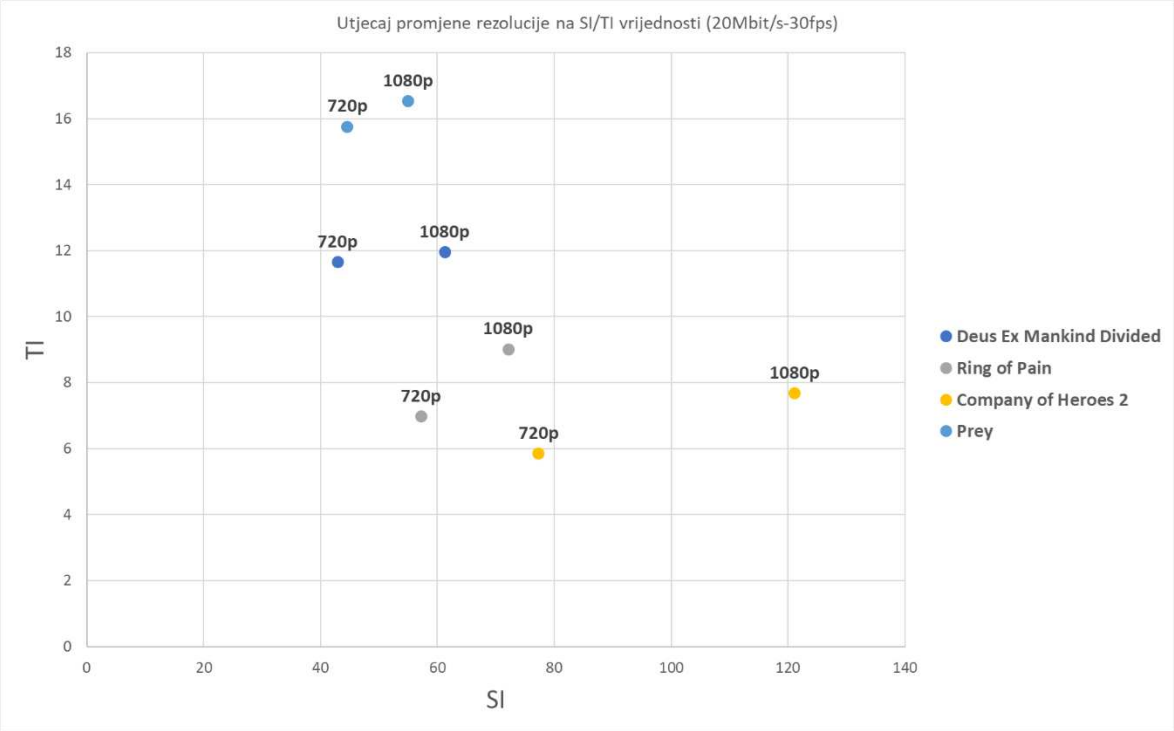

Slika 5.17 SI/TI vrijednosti za igre Deus Ex Mankind Divided, Ring of Pain, Company of Heroes 2 i Prey pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 20 Mbit/s-30 fps

Na slici 5.18 prikazan je isti graf kao i na slici 5.17, samo je brzina kodiranja smanjena na 5 Mbit/s. I u ovome slučaju dobivamo slične rezultate. Prosječno povećanje SI komponente je 30 %, za TI komponentu također dobijemo povećanje od oko 30 %. S tim da za igru *Deus Ex Mankind Divided* dobivamo smanjenje TI vrijednost u slučaju prikazanom na slici 5.18, vrlo vjerojatno zbog razlika u igranju.

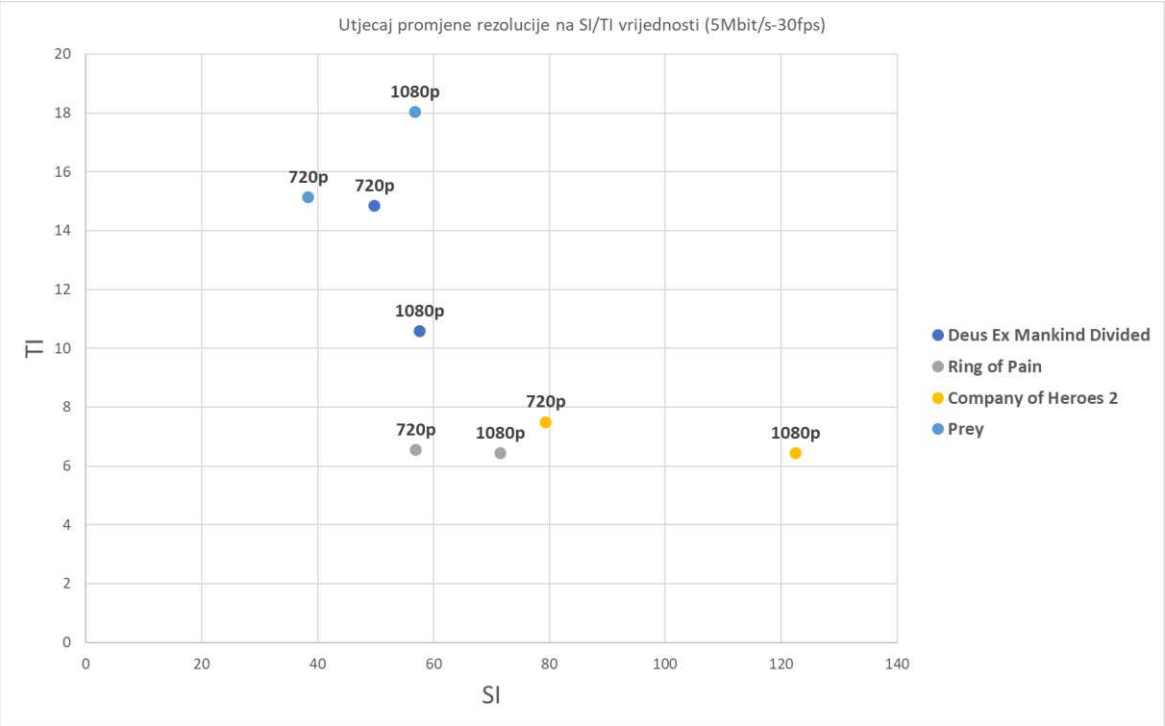

Slika 5.18 SI/TI vrijednosti za igre Deus Ex Mankind Divided, Ring of Pain, Company of Heroes 2 i Prey pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 5 Mbit/s-30 fps

5.1.3.3 Utjecaj promjene broja okvira u sekundi na SI i TI metrike

Kod analize utjecaja broja okvira na IBS/PFIM vidjeli smo povećanje PFIM vrijednosti, i možda bi isto očekivali za TI metriku, međutim povećanjem broja okvira u sekundi TI metrika se smanjuje. Na slici 5.19 prikazan je graf s parametrima brzine kodiranja 20 Mbit/s i rezoluciji za igre *Doom* (visoka TI, niska SI vrijednost), *Endless Space 2* (niska SI i niska TI vrijednost), *Dirt 5* (visoka SI i visoka TI vrijednost) i *Divinity Original Sin* (srednje niska SI, i srednje niska TI vrijednost). S grafa se vidi da je za sve igre TI vrijednost veća kad je broj okvira 30 fps. Ovo se može objasniti zbog načina na koji TI računa vrijednost, a to je uspoređivanje piksela u okviru s pikselima u susjednom okviru koji su na istoj poziciju unutar okvira. Ako povećamo broj okvira s 30 okvira u sekundi na 60 okvira u sekundi, imamo više okvira pa će susjedni okviri više sličiti jedan drugome nego kada je dostupno manje okvira.

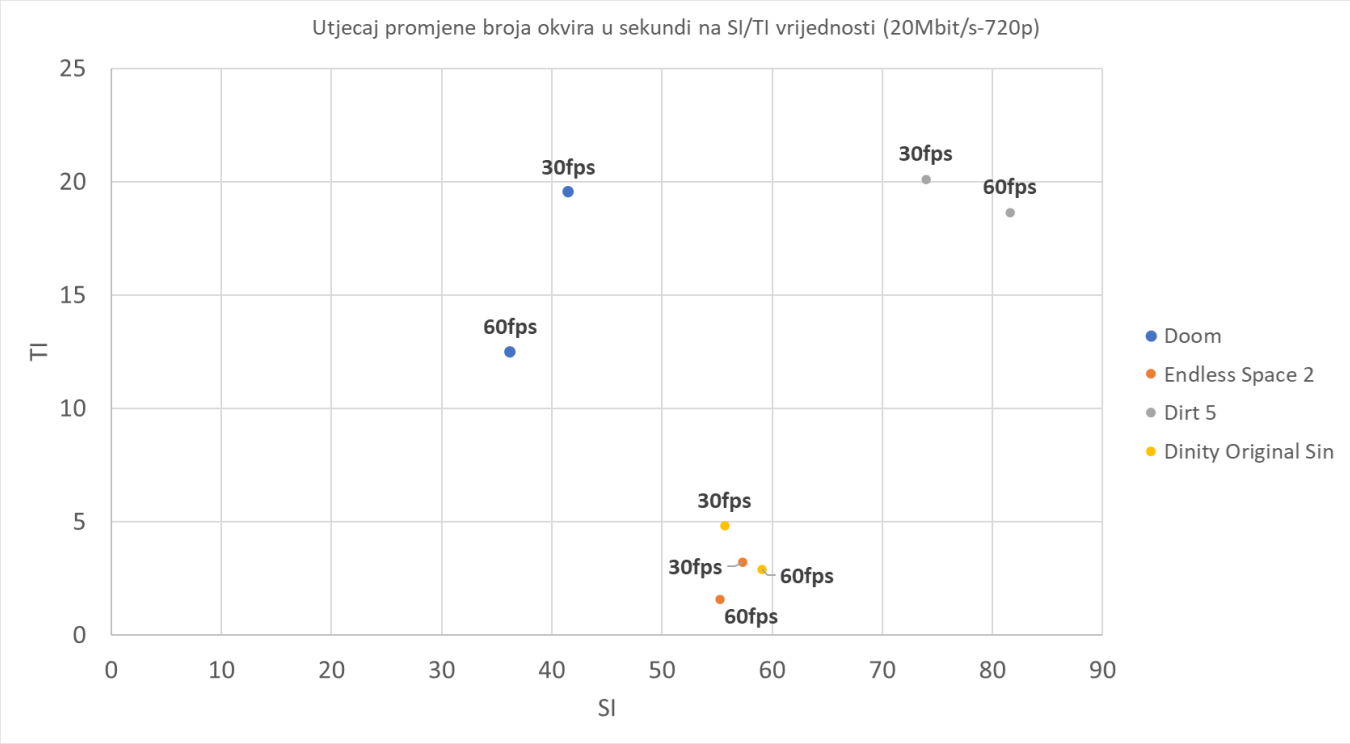

Slika 5.19 SI/TI vrijednosti za igre Doom, Endless Space 2, Dirt 5 i Divinity Original Sin pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 20 Mbit/s-720p

5.2. Analiza mrežnog prometa

Iz snimljenih *.pcap* datoteka koristeći TShark izvučeni su podatci i napravljene *.csv* datoteke za svako snimanje. Ujedno je napravljena *traffic_aggregated.csv* datoteka u kojoj su sadržane najbitnije informacije za svako snimanje. U tu datoteku su spremljene informacije o prosječnoj veličini paketa, broju paketa, najkraćem intervalu između dva slijedom poslana paketa, najvećem intervalu između dva slijednom poslana paketa, standardnoj devijaciji intervala i srednjem intervalu. Sve ove informacije su spremljene za promet koji se odvijao u smjeru poslužitelj-klijent kao i klijent-poslužitelj.

5.2.1. Analiza mrežnog prometa u smjeru poslužitelj-klijent

Pri analizi video metrika odrađena je kategorizacija igara prema PFIM/IBS i SI/TI komponentama. Kod analize mrežnoga prometa takva slična podjela nije moguća. Razlog je to što skoro sve igre imaju jednaku propusnost. Na slici 5.20 je graf na kojem su prikazana prosječna veličina paketa i prosječna propusnost za sve igre pri parametrima postavljenim na 20 Mbit/s-1080p-60 fps. Postoji mala razlika u prosječnoj veličini paketa između igara. *Grim Dawn ima* prosječnu veličinu paketa 890 okteta, a *Ring of Pain* 910

okteta, ali propusnost im je skoro jednaka što bi značilo da je broj paketa koji se pošalje tokom igranje igre *Grim Dawn* veći nego broj paketa koji se šalje za *Ring of Pain*. Igra s najvećom prosječnom propusnosti je *Dirt 5*, te ovdje ta propusnost iznosi 2655126 okteta po sekundi ili 21.24 Mbit/s što je malo iznad postavljene granice brzine kodiranja od 20 Mbit/s. Igra s najmanjom prosječnom propusnosti u ovome slučaju je *Deus Ex Mankind Divided*, koji ima propusnost 2167781 okteta po sekundi ili 17.34 Mbit/s.

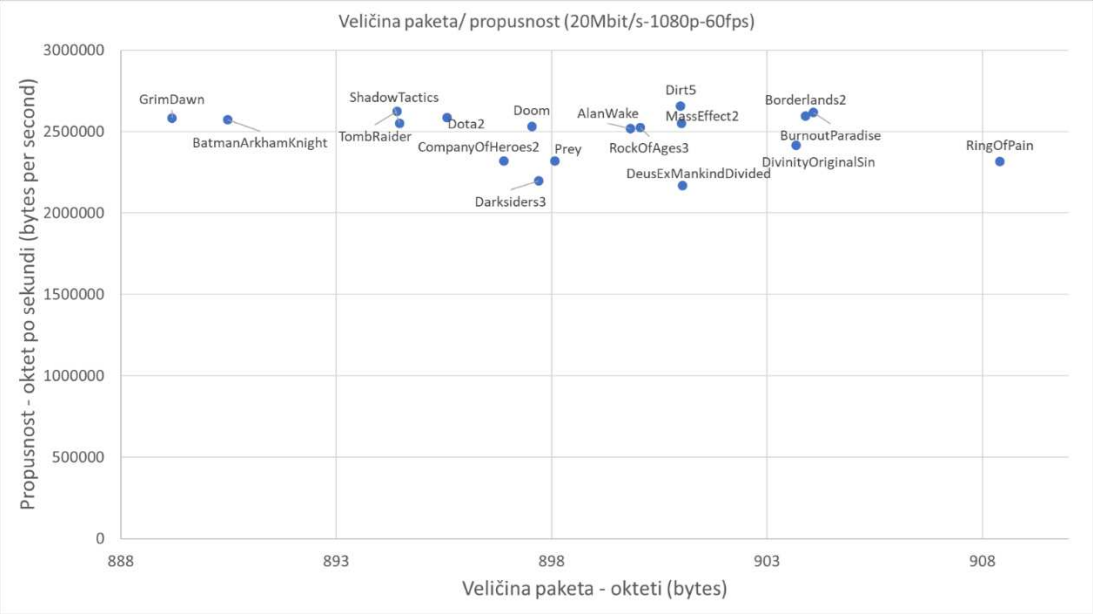

Slika 5.20 Veličina paketa/Propusnost za sve igre pri parametrima 20 Mbit/s-1080p-60 fps

Na slici 5.21 je prikazana ista vrsta grafa kao i na prijašnjoj slici, samo su vrijednosti parametara postavljene na 5 Mbit/s-720p-30 fps. Opet je vidljivo da skoro sve igre imaju istu propusnost. Postoje malo veće razlike u veličini paketa (*Dota 2* – 670 okteta, *Dirt 5* – 770 okteta), ali pošto je propusnost skoro jednaka znači da broj paketa koji se šalje je veći za igre čiji su paketi u prosjeku manji. Kategorizacija po žanrovima prema propusnosti i veličini paketa nije moguća.

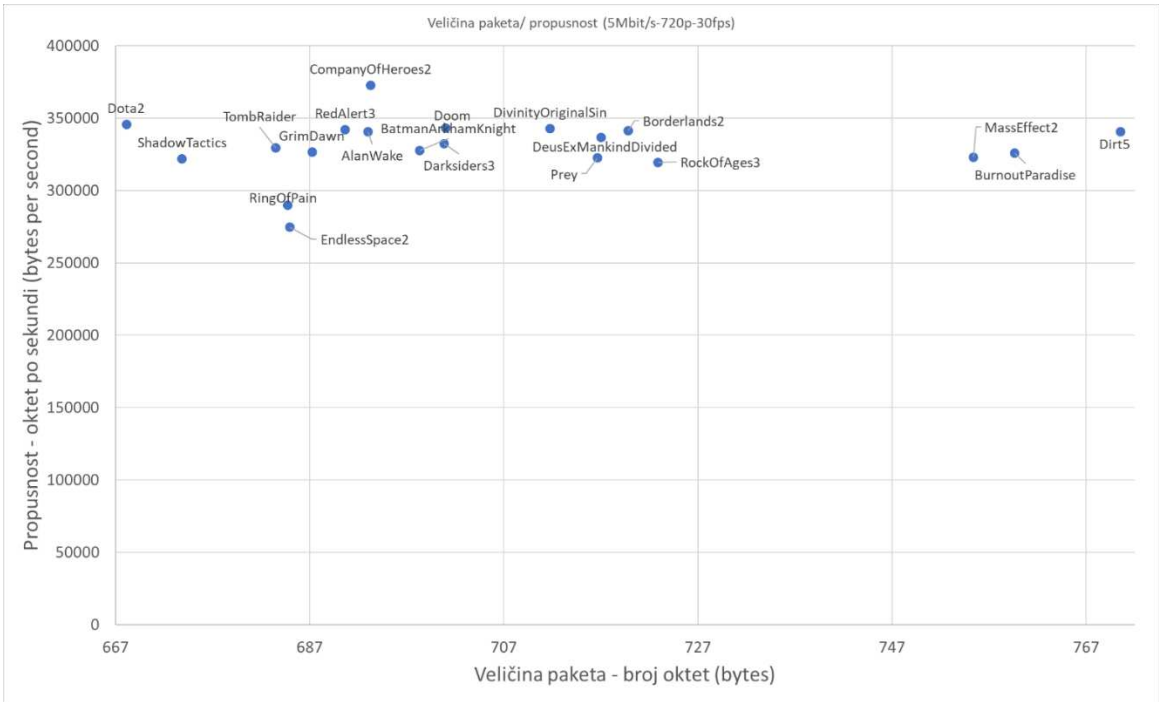

Slika 5.21 Veličina paketa/Propusnost za sve igre pri parametrima 5 Mbit/s-720p-30 fps

5.2.1.1 Utjecaj promjene brzine kodiranja na broj paketa i veličinu paketa

U ovome dijelu vidjet ćemo kako ograničenje brzine kodiranja utječe na veličinu paketa i broj paketa tijekom jedne sjednice (u trajanju od 30 sekundi). Na slici 5.22 je graf koji pokazuje prosječnu veličinu paketa i broj paketa za igru *Alan Wake* pri brzinama kodiranja od 5, 10 i 20 Mbit/s i ostalim parametrima postavljenim na 1080p i 60 fps. Prikazane su vrijednosti svih 5 snimanja za svaku kombinaciju, i snimanja su grupirana po brzinama kodiranja. Vidimo da pri povećanju brzine kodiranja dolazi do povećanja broja paketa i veličine paketa. Prosječno povećanje veličine paketa pri prelasku s 5 Mbit/s na 10 Mbit/s je 3.7 %, a pri prelasku s 10 Mbit/s na 20 Mbit/s je 8 %. Pri prelasku s 5 Mbit/s na 10 Mbit/s broj paketa je porastao za 88 %, a pri prelasku s 10 Mbit/s na 20 Mbit/s rast je 81 %.

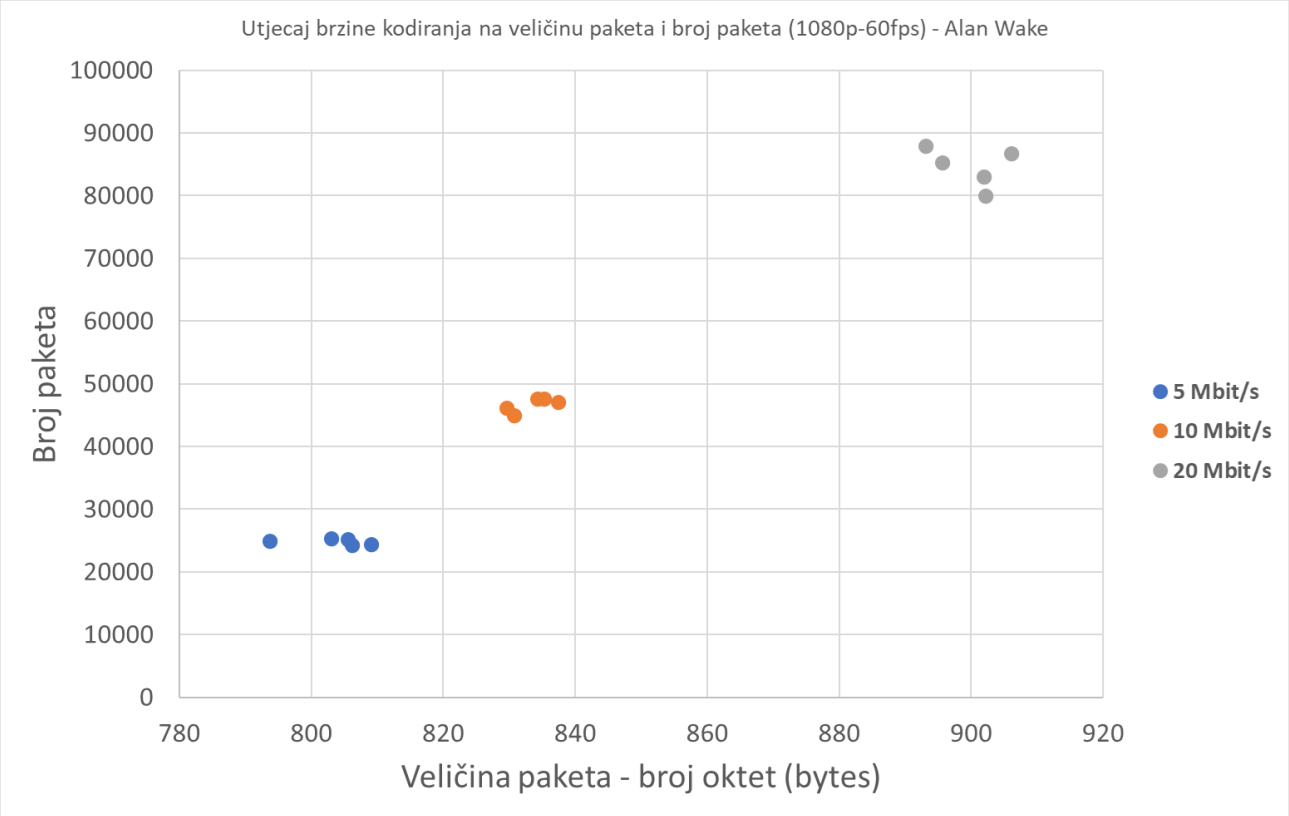

Slika 5.22 Veličina paketa/broj paketa Alan Wake (1080p-60 fps)

Na slici 5.23 je prikazana ista vrsta grafa kao i na prijašnjoj slici, samo su rezolucija i broj okvira spušteni na 720p i 30 fps, te je primjer uzet za igru *Burnout Paradise*. Opet vidimo istu situaciju kao na prijašnjoj slici. Rast veličine paketa s 5 Mbit/s na 10 Mbit/s iznosio je 6 %, dok pri prijelazu s 10 Mbit/s na 20 Mbit/s rast je 9 %.. Rast broja paketa ima jednak vrijednosti kao i prijašnji primjer (88 i 81 %).

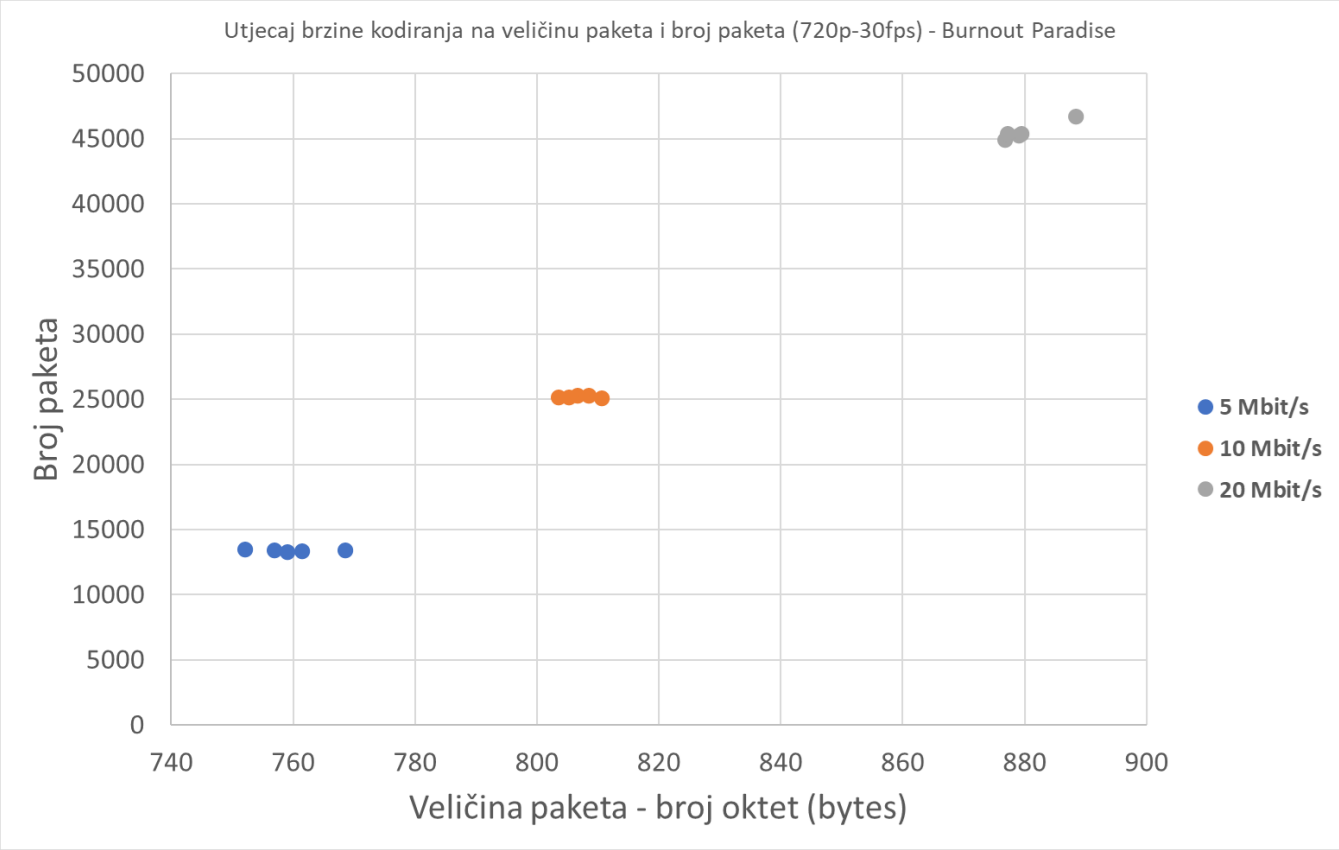

Slika 5.23 Veličina paketa/broj paketa Burnout Paradise (720p-30 fps)

5.2.1.2 Utjecaj promjene broja okvira u sekundi na propusnost i veličinu paketa

Kao i promjena rezolucije, promjena broja okvira je imala veliki utjecaj na video metrike, ali za razliku od rezolucije, promjena broja okvira ima veliki utjecaj na propusnost. Na slici 5.25 je prikazan utjecaj promjene broja okvira na propusnost i veličinu paketa, pri ograničenju parametra brzine kodiranja na 20 Mbit/s i rezolucije na 1080p. Povećanje propusnosti pri prelasku s nižeg broja okvira na veći broj okvira skoro je jednako za sve slučajeve i iznosi 95 %. Povećanje veličine paketa je također dosta konzistentno i iznosi 3 %. Povećanjem broja okvira prenosi se skoro dvostruko veća količina podataka, što znači ako igramo igre na 30 fps polovica dostupne propusnosti je neiskorištena. Ako bi se ta druga polovica koristila možda bi imali bolju kvalitetu slike za manji broj okvira, ovako kvaliteta slike ostaje potpuno ista neovisno o broju okvira u sekundi.

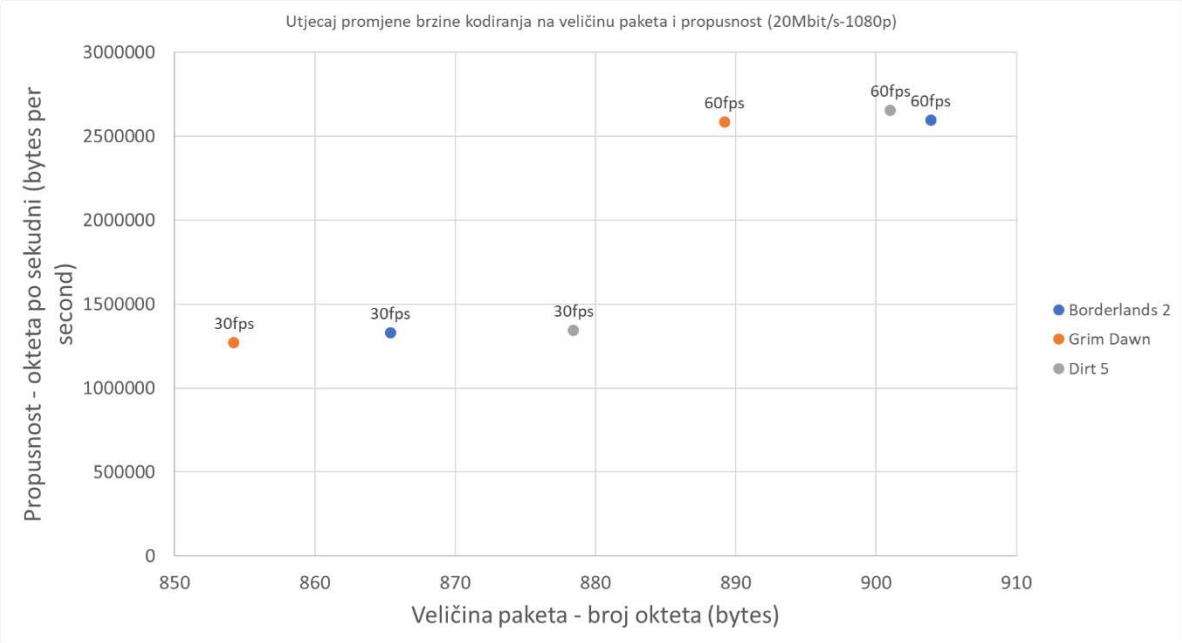

Slika 5.24 Veličina paketa/Propusnost graf utjecaj promjene broja okvira u sekundi za igre Borderlands 2, Grim Dawn, Dirt 5 (20Mbit/s-1080p)

Slika 5.26 prikazuje istu situaciju kao i prijašnji graf, jedina razlika je spuštanje ograničenja brzine kodiranja na 5 Mbit/s i rezolucije na 720p. I opet dobivamo istu situaciju, samo ovaj put veličina paketa raste u prosjeku 15 %, dok propusnost 90 %.

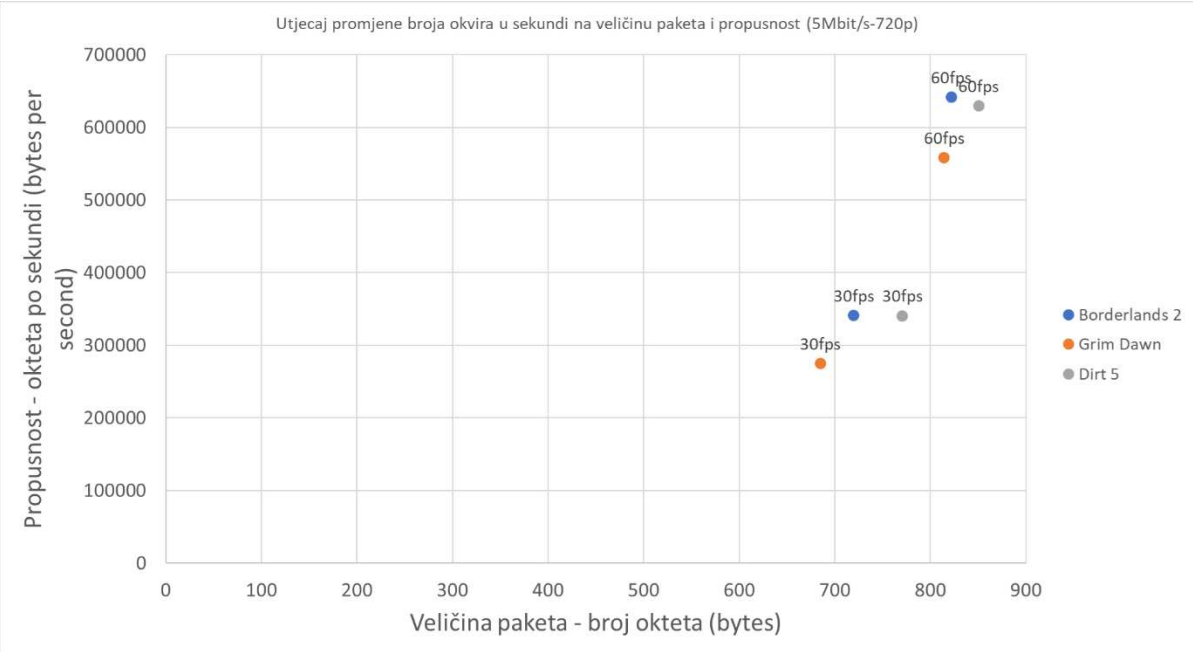

Slika 5.25 Veličina paketa/Propusnost graf utjecaj promjene broja okvira u sekundi za igre Borderlands 2, Grim Dawn, Dirt 5 (5 Mbit/s-720p)

5.2.2. Analiza mrežnog prometa u smjeru klijent-poslužitelj

Kao što smo radili podjelu igara u prethodnim poglavljima, tako ćemo je uraditi i ovdje na podatcima koje klijent šalje poslužitelju. Na slici 5.27 prikazan je graf koji radi podjelu igara prema veličini paketa i propusnosti. Vidimo da igre koje imaju najveću propusnost su strateške igre, u sredini grafa se nalaze igre iz prvog i trećeg lica, a pri dnu su trkaće igre. Informacije koje se daju putem miša su puno preciznije nego one koje se daju putem tipkovnice. Igre koje su igrane samo tipkovnicom kao *Dirt 5* i *Burnout Paradise*, nemaju veliku propusnost, a igre koje se isključivo oslanjaju na igranje mišem kao *Dota 2* šalju puno više informacija. Vjerojatno bi propusnost narasla za trkaće igre da su igrane s kontrolerom umjesto tipkovnicom, jer tada su kontrole puno preciznije i zahtijevaju više informacija za kodiranje. Zanimljivo je da što je niža propusnost to je veća prosječna veličina poslanog paketa.

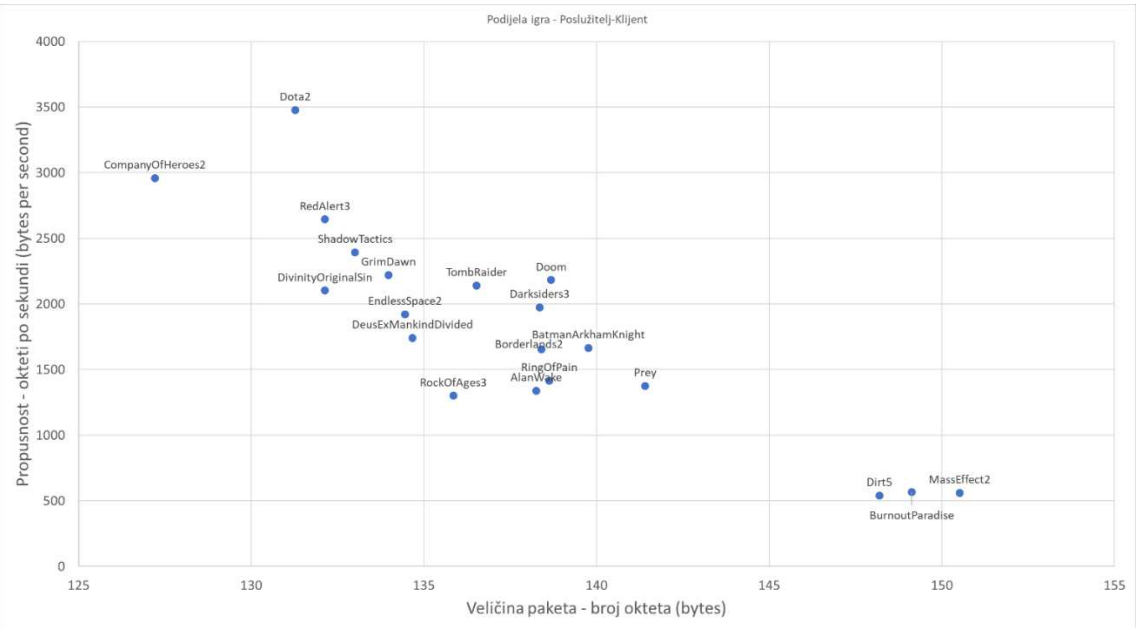

Slika 5.26 Kategorizacija igara prema broju paketa i veličini paketa - promet klijent-server

5.2.2.1 Utjecaj promjene parametara na propusnost i veličinu paketa

Promjena rezolucije, promjena broja okvira u sekundi i promjena brzine kodiranja nemaju nikakav utjecaj na količinu podataka koje klijent šalje poslužitelju. To je zato što kod igranja je jako bitno da se sve korisničke naredbe točno registriraju, a i količina podataka koje šalje korisnik je relativno mala, tako da nema potrebe za dodatnom redukcijom tih podataka. Najgori slučaj kada se prenosilo najviše podataka bilo je za igru *Dota 2*, i tada je

propusnost u smjeru klijent poslužitelj bila samo 0.028 Mbit/s, što ne bi trebalo imati nikakvog utjecaja na kvalitetu slike ili bilo koje druge komponente.

5.3. Sažetak ključnih zaključaka

Analizom utjecaja promjene parametara na metrike prostorne i vremenske složenosti videa, možemo doći do zaključka da promjena brzine kodiranja nije imala utjecaja ni na prostorne i na vremenske metrike. Rezolucija je najviše utjecala na prostorne metrike, a broj okvira u sekundi je imao utjecaja na vremenske metrike.

Igre iz prvog i trećeg lica imale su slične vrijednosti video metrika, te su obično imale visoke vrijednosti vremenske složenosti i niske prostorne. Za igre koji imaju pogled odozgo situacija je bila obrnuta, metrike vremenske složenosti su malih vrijednosti, a metrike prostorne složenosti imaju visoke vrijednosti.

Pri analizi mrežnog prometa u smjeru poslužitelj-klijent nije bilo moguće uraditi kategorizaciju kao pri analizi video metrika, ali smo utvrdili da povećanjem brzine kodiranja raste veličina poslanog paketa i naravno ukupan broj paketa koji se šalje. Promjena rezolucija nije imala utjecaja na propusnost, dok smanjenjem broja okvira u sekundi sa 60 fps na 30 fps propusnost bi se približno prepolovila u odnosu na postavljenu brzinu kodiranja.

Analizom mrežnog prometa u smjeru klijent-poslužitelj moglo se uočiti da vrsta kontrolera kojom se igra ima velik utjecaj na količinu mrežnog prometa. Tako za igre koje su igrane skoro isključivo mišem (većinom igre koje imaju pogled odozgo) slano je puno više podataka nego za igre koje su igrane samo tipkovnicom (trkaće igre).

6. Procjena parametara korištenjem metoda strojnog učenja

Promet koji se odvija između poslužitelja i klijenta je najčešće kriptiran, tako da davatelji mrežnih usluga nemaju uvid u performanse i kvalitetu usluga strujanja video sadržaja. U ovome poglavlju korištenjem metoda strojnog učenja pokušat će se iz mrežnog prometa predvidjeti parametri rezolucije, brzine kodiranja i broja okvira u sekundi za razne igre navedene u prethodnim poglavljima.

6.1. Korišteni alati

Za provedbu predviđanja parametara korišten je programski jezik Python [36], te knjižnice (engl. *libraries*) Scikit-learn [35] i Pandas [37]. Scikit-learn je knjižnica za Python koja sadrži razne algoritme koji se koriste u svrhe strojnog učenja. Pandas služi za lagano upravljanje i analizu podataka unutar Python-a.

6.2. Priprema ulaznih podataka

Za svaku sjednicu dostupna je *.pcap* datoteka sa snimljenim dolaznim i odlaznim prometom s klijentskog računala koje je spojeno na Internet. Sve *.pcap* datoteke su filtrirane da sadrže samo promet koji se odvijao između poslužitelja i klijenta, te je tako filtrirani promet pohranjen u *.csv* datoteku. Iz svake *.csv* datoteke izračunate su osnovne statistike mrežnog prometa kao što su: broj paketa, broj paketa većih od 100 okteta, ukupan broj okteta i prosječna propusnost. Uz to za sve mrežne statistike izračunati su prosjek, raspršenost (engl. *variance*), standardna devijacija, koeficijent raspršenosti (engl. *coefficient of variation*), stupanj neispunjenosti u raspodjeli (engl. *skewness*), stupanj prljavosti u raspodjeli (engl. *kurtosis*), minimum i maksimum. Svi izračuni primijenjeni su za primljeni promet (od poslužitelja prema klijentu) i poslani promet. Također je izračunata prosječna propusnost u prvoj sekundi, prvih 5 sekundi i prvih 10 sekundi u smjeru poslužitelj-klijent. Ukupno je 109 različitih značajki (engl. *feature*). Skripta za računanje ulaznih podataka preuzeta je sa Zavoda za telekomunikacije [34]. Za algoritme

gdje je to potrebno ulazni podatci su skalirani nakon učitavanja u program za procjenu parametara koristeći Standard Scaler [38].

Predviđat će se parametri brzine kodiranja videa, broja okvira u sekundi i rezolucije. Svaki parametar će se predviđati zasebno i svi parametri su podijeljeni u klase. Jedino brzina kodiranja videa ima 3 klase (5 Mbit/s, 10 Mbit/s i 20 Mbit/s), dok broj okvira u sekundi ima 2 klase (30 fps i 60 fps), kao i parametar rezolucije (720p i 1080p). Za svaki parametar je naučen zasebni model.

6.3. Ocjenjivanje modela strojnog učenja

Standardni način prikazivanja rezultata klasifikacije je putem matrice zabune (engl. *confusion matrix*). Matrica zabune za binarnu klasifikaciju broja okvira u sekundi (Slika 6.1) ima 4 različite vrijednosti:

1) TP (engl. *true positive*) je broj ispravno klasificiranih *30 FPS* vrijednosti
2) FP (engl. *false positive*) je broj vrijednosti koje su pogrešno klasificirane kao *30 FPS,*
3) FN (engl. *false negative*) je broj vrijednosti koje su pogrešno klasificirane kao *60 FPS,*
4) TN (engl. *true negative*) je broj vrijednosti koje su ispravno klasificirane kao *60 FPS.*

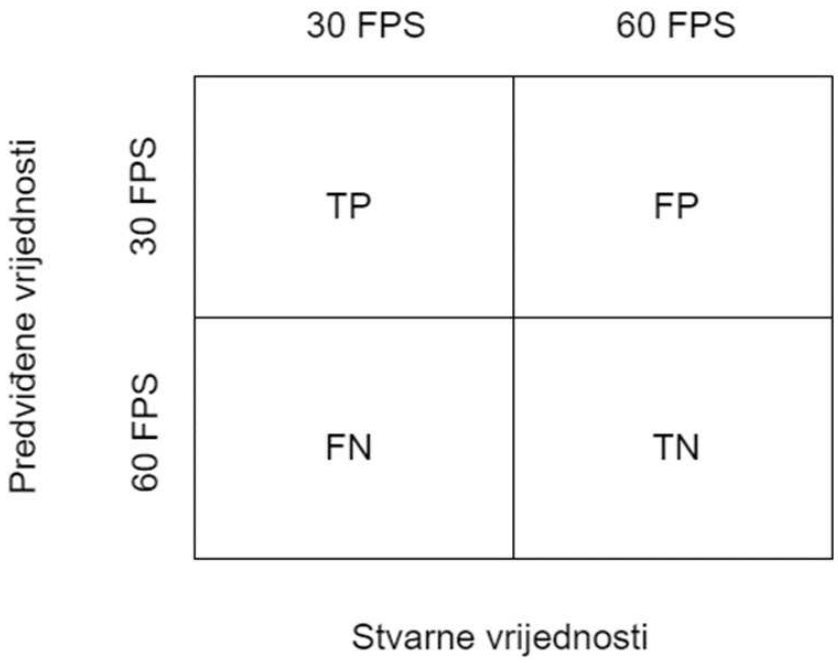

Slika 6.1 Primjer matrice zabune za binarnu klasifikaciju broja okvira u sekundi

Za ocjenjivanje modela strojnog učenja koristit će se 4 različite mjere izračunate iz matrice zabune [45]:

1) Točnost (engl. *accuracy*): Pokazuje postotak ispravno predviđenih vrijednosti. Računa se prema formuli (4).

$$Točnost = \frac{TN + TP}{TN + FP + TP + FN} \quad (4)$$

2) Preciznost (engl. *precision*): Pokazuje postotak ispravno predviđenih vrijednosti u skupu predviđenih pozitivnih vrijednosti (5).

$$Preciznost = \frac{TP}{TP+FP} \quad (5)$$

3) Odziv (engl. *recall*): Prikazuje postotak ispravno predviđenih vrijednosti u skupu stvarnih pozitivnih vrijednosti (6).

$$Odziv = \frac{TP}{TP+FN} \quad (6)$$

4) F1-mjera (engl. *F1 score*): F1-mjera je harmonijska sredina između preciznosti i odziva (7). Harmonijska sredina se koristi umjesto aritmetičke ili geometrijske sredine zato što je najstroža, te njome dobivamo pesimističnu procjenu [47].

$$F1\ mjera = \frac{2 * Preciznost * Odziv}{Preciznost + Odziv} \quad (7)$$

6.4. Korišteni algoritmi

Predviđanje parametara rezolucije, brzine kodiranja i broja okvira u sekundi riješit će se primjenom nadziranog učenja i klasifikacije parametara. Odabrana su 3 različita algoritma za pristup ovome problemu:

1) Logistička regresija (engl. *Logistic Regression*): Procjenjuje vjerojatnost neke klase, na temelju zadanog skupa neovisnih značajki [41].
2) Klasifikator slučajnih šuma (engl. *Random Forest Classifier*): Sastoji se od niza klasifikatora stabala gdje su klasifikatori primijenjeni na različitim podskupovima danog skupa podataka, i svako stablo daje glas za klasu po kojoj bi se trebao klasificirati ulazni vektor [39]. Zbog toga što se uzima prosjek svih predviđanja klasifikator slučajnih šuma nema problema s prenaučenosti (engl. *overfitting*) [39].
3) Metoda potpornih vektora (engl. *Support Vector Machines – SVM*): Temelji se na statističkoj teoriji učenja i radi na principu određivanja granica odlučivanja koje bi trebale optimalno razdijeliti klase [39]. Glavne prednosti metoda potpornih vektora su [40]: 1) dobra učinkovitost u prostorima velikih dimenzija, 2) učinkovitost kada je broj dimenzija veći od broja uzoraka, 3) memorijska učinkovitost i 4)

svestranost. Metode potpornih vektora ne daju izravno procjene vjerojatnosti, već se mogu izračunati pomoću peterostruke unakrsne provjere.

6.5. Analiza performansi modela

U ovome poglavlju će se analizirati rezultati predviđanja za različite algoritme strojnog učenja. Polovica ulaznih podataka koristi se za treniranje modela, a druga polovica za testiranje. Odabir seta podataka za treniranje i za testiranje odrađen je pomoću funkcija iz knjižice Pandas. Koristeći RandomForestClassifier [44] odabrane su najbitnije značajke.

6.5.1. Predviđanje parametra brzine kodiranja

U ovome poglavlju analizirat će se rezultati predviđanja brzine kodiranja za različite algoritme strojnog učenja. Ukupno su tri različite klase brzine kodiranja: 5 Mbit/s, 10 Mbit/s i 20 Mbit/s. Odabir najbitnijih značajki odrađen je koristeći RandomForestClassifier. Prikazat će se samo rezultati nakon odabira najboljih značajki, osim u prvom primjeru klasifikacije brzine kodiranja korištenjem logističke regresije, gdje su prikazani rezultati za sve značajke kao i za najbitnije značajke. Prosječno poboljšanje ukupne točnosti pri odabiru najbitnijih značajki je bilo od 1 do 2 postotna boda. Ukupno je oko 40 najboljih značajki i sve su u smjeru poslužitelj-klijent. Među izabranim najbitnijim značajkama su prosječna propusnost, ukupan broj paketa, propusnost u prvoj, petoj i desetoj sekundi, stupanj neispunjenosti u raspodjeli veličine paketa i ukupan broj okteta.

6.5.1.1 Logistička regresija

Koristeći algoritam logističke regresije istreniran je model koji predviđa parametara brzine kodiranja. U tablici 6.1 su prikazani potpuni rezultati predviđanja, za slučaj kada pri treniranju koristimo sve značajke i kada koristimo samo najbolje značajke. Ukupna točnost kada koristimo sve značajke iznosi 98.05 %, a kada koristimo samo najbolje značajke ukupna točnost za sve klase je 99.47 %. Najveća točnost kada se koriste sve značajke je za klasu 5 Mbit/s. Pri korištenju najbitnijih značajki za učenje, točnost za sve klase je preko 99 %. Odziv pri korištenju svih značajki je najniži za klasu 10 Mbit/s, što ukazuje na to da se vrijednosti od 5 Mbit/s i 20 Mbit/s pogrešno svrstavaju u susjednu klasu 10 Mbit/s. Korištenjem najbitnijih značajki dobijemo savršen odziv za klasu 10 Mbit/s.

	Brzina kodiranja	Točnost	Preciznost	Odziv	F1-mjera
SVE ZNAČAJKE	5 Mbit/s	0.9982	1.0	1.0	1.0
	10 Mbit/s	0.9805	0.98	0.96	0.97
	20 Mbit/s	0.9823	0.96	0.99	0.97
NAJBOLJE ZNAČAJKE	5 Mbit/s	0.9982	1.0	1.0	1.0
	10 Mbit/s	0.9947	0.98	1.0	0.99
	20 Mbit/s	0.9965	1.0	0.99	0.99

Tablica 6.1 Rezultati klasifikacije brzine kodiranja koristeći logističku regresiju

Na slici 6.2 prikazana je matrica zabune, pri predviđanju brzine kodiranja koristeći algoritam logističke regresije i sve značajke. Najčešće greška je klasificiranje klase 10 Mbit/s kao 20 Mbit/s.

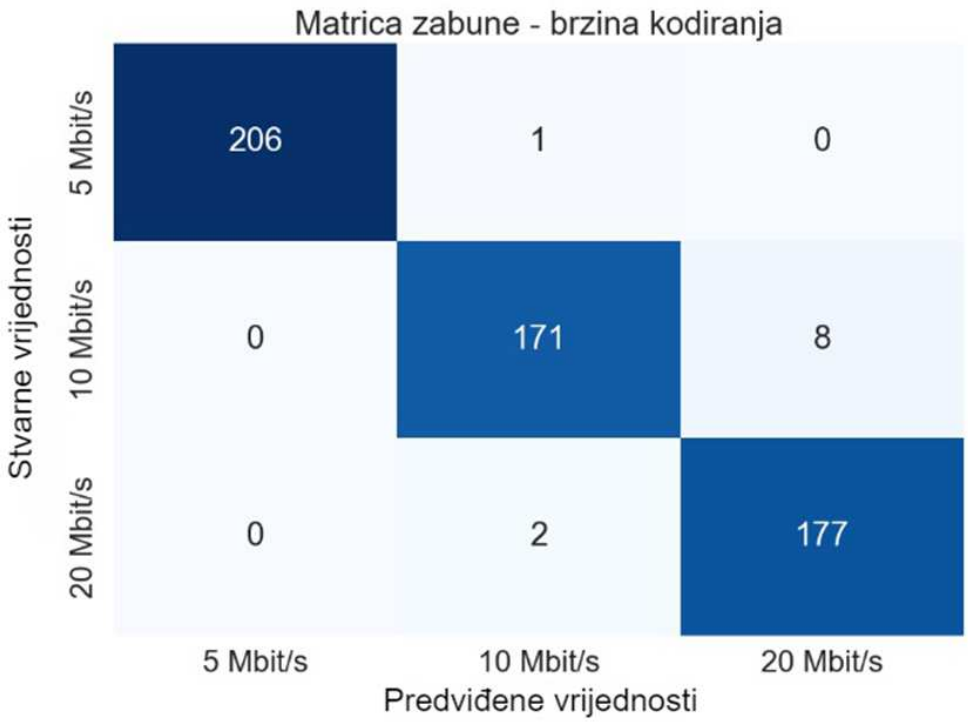

Slika 6.2 Matrica zabune (Logistička regresija) - predviđanje brzine kodiranja

Na slici 6.3 prikazana je matrica zabune za predviđanje brzine kodiranja, koristeći logističku regresiju i odabir najboljih značajki. U usporedbi s prijašnjom matricom, može se uočiti da su sve neispravno klasificirane klase čija je stvarna vrijednosti 10 Mbit/s (kojih je bilo 8), sada ispravno klasificirane.

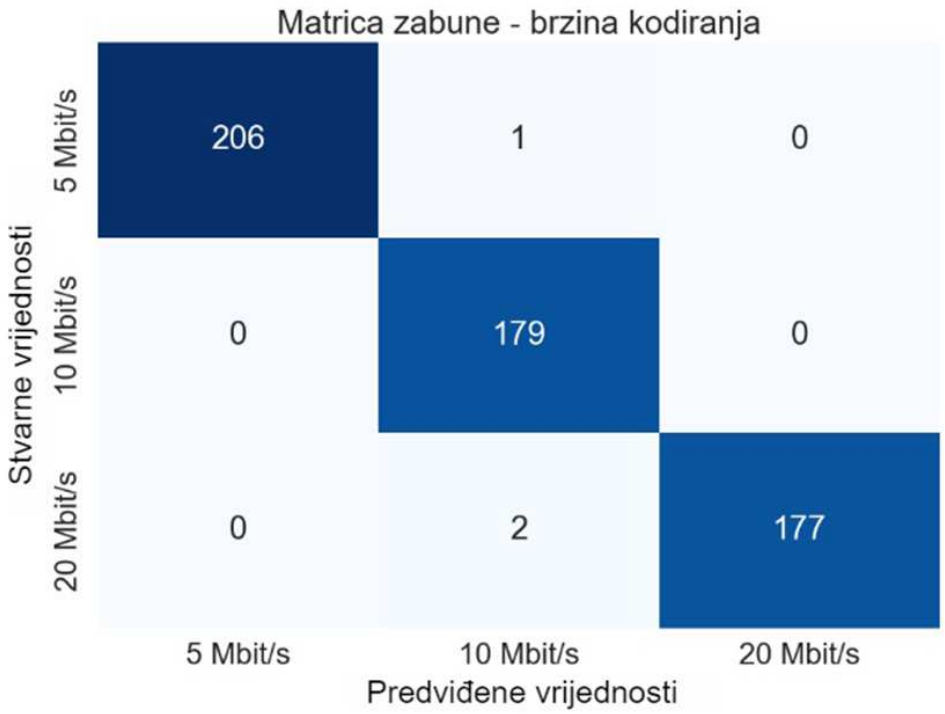

Slika 6.3 Matrica zabune (Logistička regresija) - predviđanje brzine kodiranja uz izbor najboljih značajki (RandomForestClassifier)

6.5.1.2 Klasifikator slučajnih šuma

U ovome poglavlju analizirat će se rezultati predviđanja brzine kodiranje, koristeći klasifikatora slučajnih šuma. U tablici 6.3 prikazani su potpuni rezultati ovoga predviđanja. Ukupna točnost za sve klase je 98.44 %, što je nešto lošiji rezultat nego za logističku regresiju. Točnost je najmanja za klasu 10 Mbit/s i iznosi 98.44 %. Odziv za tu klasu je 100 %, a preciznost 96 %, što bi značilo da su sve stvarne vrijednosti od 10 Mbit/s ispravno klasificirane, dok se vrijednosti od 5 Mbit/s i 20 Mbit/s, ponekad krivo klasificiraju kao 10 Mbit/s.

Tablica 6.2 Rezultati klasifikacije brzine kodiranja koristeći klasifikator slučajnih šuma

Brzina kodiranja	Točnost	Preciznost	Odziv	F1- mjera
5 Mbit/s	0.9913	1.0	0.98	0.99
10 Mbit/s	0.9844	0.96	1.0	0.98
20 Mbit/s	0.9931	1.0	0.98	0.99

Na slici 6.4 prikazana ja matrica zabune za ovaj slučaj. Može se uočiti da klasa 5 Mbit/s se pet puta pogrešno klasificirala kao 10 Mbit/s, dok se klasa 20 Mbit/s četiri puta pogrešno klasificirala kao 10 Mbit/s.

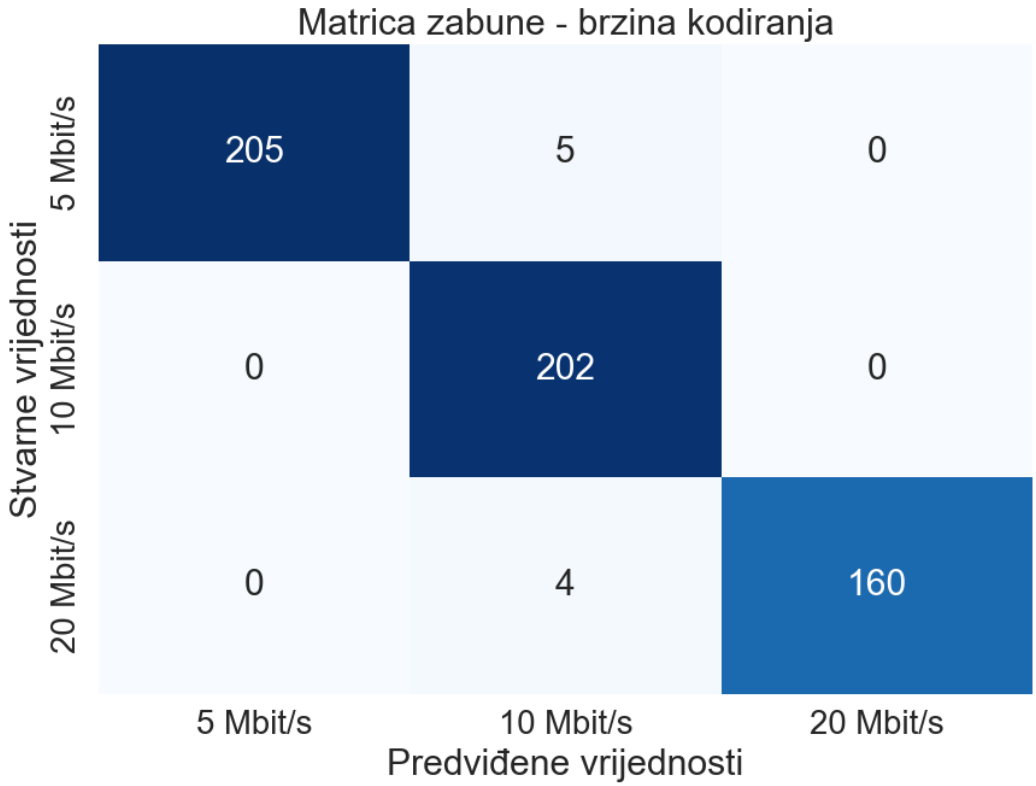

Slika 6.4 Matrica zabune (Klasifikator slučajnih šuma) - predviđanje brzine kodiranje

6.5.1.3 Metoda potpornih vektora

Koristeći metode potpornih vektora, napravljen je model procjene brzine kodiranja. U tablici 6.3 prikazani su potpuni rezultati procjene brzine kodiranja iz najbitnijih značajki. Za biranje značajki korišten je RandomForestClassifier, i s njim dobijemo poboljšanje točnosti od 1.5 postotnih boda. Ukupna točnost za ovaj slučaj je 99.07 %. Iz tablice vidimo da je odziv za klasu 10 Mbit/s jednak 100 %, što znači da su se sve stvarne vrijednosti od 10 Mbit/s ispravno klasificirale. Najmanju preciznost ima klasa 10 Mbit/s, što bi značilo da je najveći broj pogrešno klasificiranih vrijednosti svrstano u klasu 10 Mbit/s.

Tablica 6.3 Rezultati klasifikacije brzine kodiranja koristeći metode potpornih vektora

Brzina kodiranja	Točnost	Preciznost	Odziv	F1- mjera
5 Mbit/s	0.9963	1.0	0.99	0.99
10 Mbit/s	0.9925	0.98	1.0	0.99
20 Mbit/s	0.9925	0.99	0.98	0.99

Iz matrice zabune za ovaj slučaj (Slika 6.5) vidimo da se stvarna vrijednost od 20 Mbit/s tri puta pogrešno klasificirala kao 10 Mbit/s. Stvarna vrijednost 5 Mbit/s se jednom pogrešno klasificirala kao 10 Mbit/s i jednom kao 20 Mbit/s.

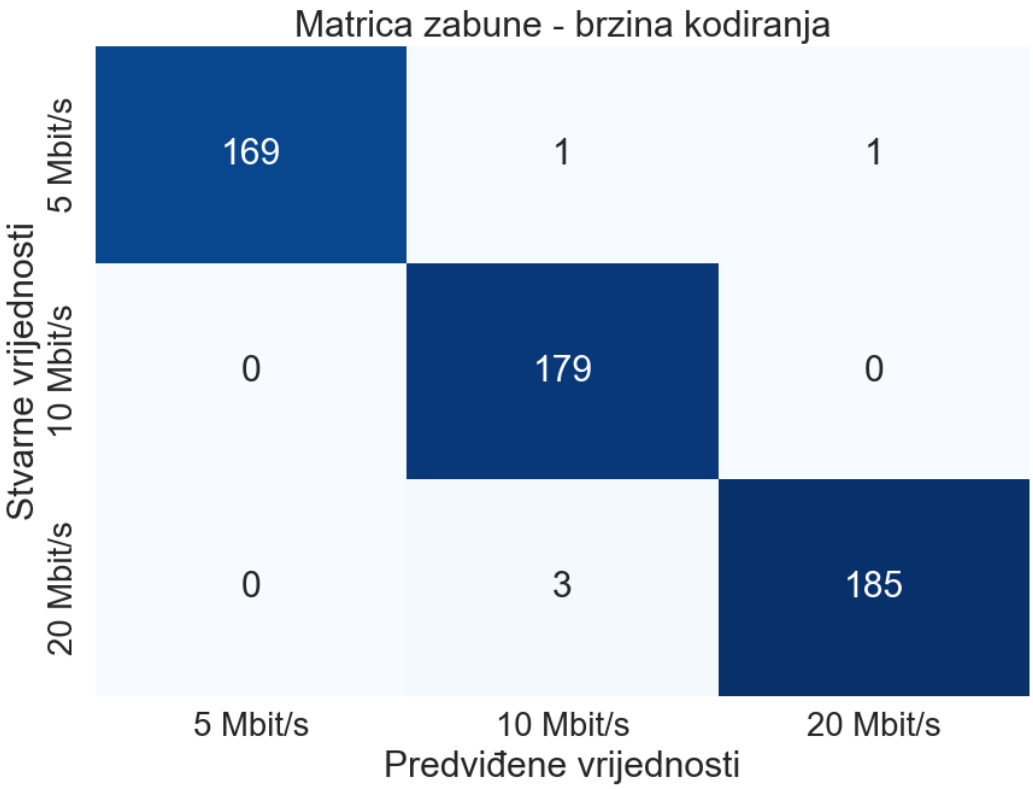

Slika 6.5 Matrica zabune (Metoda potpornih vektora) - predviđanje brzine kodiranje

6.5.2. Predviđanje parametra broj okvira u sekundi

U ovome poglavlju analizirat će se rezultati predviđanja broja okvir u sekundi za različite algoritme strojnog učenja. Ukupno su dvije različite klase za broj okvira u sekundi: 30 fps i 60 fps. Kao i pri predviđanju brzine kodiranja odabir najbitnijih značajki odrađen je koristeći RandomForestClassifier. Prikazat će se samo rezultati nakon odabira najboljih značajki. Najbolje značajke slične su onima kao kod predviđanja brzine kodiranja. Uglavnom su sve u smjeru poslužitelj-klijent, s tim da ima par iznimki, kao ukupan broj paketa i okteta u smjeru klijent-poslužitelj.

6.5.2.1 Logistička regresija

Model za predviđanje broja okvira u sekundi izrađen je pomoću algoritma logističke regresije. Potpuni rezultati klasifikacije prikazani su u tablici 6.4. Ukupna točnost za sve klase je 88.95 %. Klasa 30 fps ima veću preciznost nego klasa 60 fps, što upućuje na to da se klasa 30 fps češće pogrešno predvidi kao 60 fps, nego što se 60 fps pogrešno predvidi

kao 30 fps. Korištenjem odabira najboljih značajki za ovaj slučaj ne dobivamo poboljšanje u točnosti.

Tablica 6.4 Rezultati klasifikacije broja okvira u sekundi koristeći logističku regresiju

Broj okvira u sekundi	Točnost	Preciznost	Odziv	F1- mjera
30 fps	0.8895	0.91	0.86	0.89
60 fps	0.8895	0.86	0.91	0.88

6.5.2.2 Klasifikator slučajnih šuma

Rezultati predviđanja broja okvira u sekundi koristeći klasifikator slučajnih šuma prikazani su u tablici 6.5. Ukupna točnost za sve klase je 98.53 %, što je za 10 postotnih bodova bolje nego točnost kod algoritam logističke regresije. Skoro jednake visoke vrijednosti preciznosti i odziva za obje klase ukazuju na to da rijetko dolazi do greške pri predviđanju klasa i što upućuje na to da je postotak pogrešno predviđenih 30 fps klasa, jednak postotku pogrešno predviđenih 60 fps klasa. Broj okvira u sekundi je direktno povezan s propusnosti, jer pri prelasku sa 60 fps, na 30 fps, propusnost se prepolovi. To je jedan od razloga zašto dobivamo ovako visoku točnost.

Tablica 6.5 Rezultati klasifikacije broja okvira u sekundi koristeći klasifikator slučajnih šuma

Broj okvira u sekundi	Točnost	Preciznost	Odziv	F1- mjera
30 fps	0.9853	0.98	0.98	0.98
60 fps	0.9853	0.99	0.99	0.99

6.5.2.3 Metoda potpornih vektora

Koristeći metode potpornih vektora, napravljen je model procjene broja okvira u sekundi. Nakon odabira najbitnijih značajki dobivamo poboljšanje u ukupnoj točnosti za oko 9 postotnih bodova. U tablici 6.6 prikazani su ukupni rezultati predviđanja broja okvira, uz

izbor najbitnijih značajki. Ukupna točnost za ovaj slučaj je 99.48 %. Iz tablice se može uočiti da je predviđanje skoro savršeno. Preciznost za klasu 30 fps je 100 %, a za klasu 60 fps je 99%, što znači da je mali broj stvarnih vrijednosti 30 fps pogrešno predviđeno kao 60 fps, a da su sve stvarne vrijednosti 60 fps ispravno klasificirane. Metode potpornih vektora su dale najbolje rezultate u predviđanju broja okvira u sekundi.

Tablica 6.6 Rezultati klasifikacije brzine kodiranja koristeći metode potpornih vektora

Broj okvira u sekundi	Točnost	Preciznost	Odziv	F1- mjera
30 fps	0.9948	1.0	0.99	0.99
60 fps	0.9948	0.99	1.0	0.99

6.5.3. Previđanje parametra rezolucije

U ovome poglavlju analizirat će se rezultati predviđanja rezolucije za različite algoritme strojnog učenja. Ukupno imamo dvije klase rezolucije: 720p i 1080p. Opet je korišten RandomForestClassifier za odabir najbitnijih značajki. U najbitnije značajke uključene su skoro sve značajke osim minimalne veličine paketa za promet u oba smjera i omjera ukupne veličine prometa u smjeru poslužitelj-klijent i klijent-poslužitelj. Prikazat će se samo rezultati nakon odabira najboljih značajki.

6.5.3.1 Logistička regresija

Predviđanje rezolucije iz mrežnih podataka je puno teži zadatak nego predviđanje brzine kodiranja i broja okvira u sekundi, jer promjena rezolucije ne utječe na propusnost. U tablici 6.7 prikazani su potpuni rezultati predviđanja rezolucija pomoću modela logističke regresije. Ukupna točnost za sve primjere je bila 55.81 %, što je značajno niže nego točnost za predviđanje broja okvira u sekundi i brzine kodiranja. Iz metrika preciznosti i odziva vidi se da se stvarna vrijednost 720p češće pogrešno klasificirala kao 1080p, nego što se 1080p pogrešno klasificirala kao 720p.

Tablica 6.7 Rezultati klasifikacije rezolucije koristeći logističku regresiju

Rezolucija	Točnost	Preciznost	Odziv	F1- mjera
720p	0.5581	0.60	0.49	0.54
1080p	0.5581	0.53	0.64	0.58

6.5.3.2 Klasifikator slučajnih šuma

Ukupna točnost pri predviđanju rezolucije koristeći klasifikator slučajnih šuma je 66.37 %. Potpuni rezultati za ovaj slučaj prikazani su u tablici 6.8. Odziv za klasu 720p je niži nego odziv za klasu 1080p, to ukazuje na to da se rezolucija 720p češće pogrešno klasificira kao rezolucija 1080p, nego što se klasa 1080p pogrešno klasificira kao 720p. Klasifikator slučajnih šuma radi bolje predviđanje rezolucije nego što to radi logistička regresija, ali točnost je još uvijek puno manja nego pri predviđanju brzine kodiranja i broja okvira u sekundi.

Tablica 6.8 Rezultati klasifikacije rezolucije koristeći klasifikator slučajnih šuma

Rezolucija	Točnost	Preciznost	Odziv	F1- mjera
720p	0.6637	0.66	0.60	0.63
1080p	0.6637	0.67	0.72	0.69

6.5.3.3 Metoda potpornih vektora

U tablici 6.9 prikazani su potpuni rezultati klasifikacije rezolucije koristeći metode potpornih vektora uz izabrane najbitnije značajke. Ukupna točnost iznosi 61.28 %, što je niže nego za klasifikator slučajnih šuma, a više nego logistička regresija. Nakon odabira najbitnijih značajki dobivamo poboljšanje u ukupnoj točnosti za oko 5 postotnih bodova. Preciznost i odziv za klasu 720p i 1080p su skoro identični, što upućuje na to da je postotak pogrešno predviđenih 720p klasa, jednak postotku pogrešno predviđenih 1080p klasa.

Tablica 6.9 Rezultati klasifikacije rezolucije koristeći metode potpornih vektora

Rezolucija	Točnost	Preciznost	Odziv	F1- mjera
720p	0.6128	0.62	0.60	0.61
1080p	0.6128	0.61	0.63	0.62

6.5.4. Sažetak ključnih zaključaka

Sve analizirane metode dale su dobra predviđanja brzine kodiranja. Točnost je uvijek bila oko 98 % do 99 %. Najbolji rezultat dobiven je korištenjem logističke regresije, zatim metode potpornih vektora i naposljetku klasifikator slučajnih šuma. Modeli za predviđanje brzine kodiranja pokazali su visoke performanse (točnosti) zbog toga što propusnost pri 60 fps-a i brzina kodiranja imaju skoro identične vrijednosti. Problem nastaje kada spustimo broj okvira u sekundi na 30 fps, jer tada se propusnost prepolovi, te je najčešća greška bila klasifikacija 20 Mbit/s kao 10 Mbit/s i 10 Mbit/s kao 5 Mbit/s. Najbitnije značajke pri ovome predviđanju su sve bile u smjeru poslužitelj-klijent. Pri predviđanju korištenjem samo najbitnijih značajki dobivalo se poboljšanje od 0.5 do 2 postotna boda. Predviđanje broja okvira u sekundi je imalo najbolju točnost za metode potpornih vektora (99 %), zatim za klasifikator slučajnih šuma (98 %) i naposljetku logističku regresiju (90 %). Odabir najbitnijih značajki imao je velik utjecaj na metode potpornih vektora, gdje je dobiveno poboljšanje od 9 postotnih bodova. Najbitnije značajke su skoro identične onima u predviđanju brzine kodiranja i većinom su u smjeru poslužitelj-klijent. Predviđanje rezolucije je predstavljalo najveći izazov. Koristeći klasifikator slučajnih šuma dobila se točnost od 67 %, zatim za metode potpornih vektora točnost je bila oko 61 %, a najlošiji rezultati dobiveni su koristeći logističku regresiju s točnošću od 55 %. Izbor najbitnijih značajki za metode potpornih vektora donijelo je poboljšanje u točnosti od 5 postotnih bodova, dok za logističku regresiju izbor najboljih parametara je negativno utjecao na rezultate, te je točnost za taj slučaj smanjena za 5 postotnih bodova. Za razliku od značajki za predviđanja brzine kodiranja i broja okvira u sekundi, najbitnije značajke pri predviđanju rezolucije su sadržavale statistike u oba smjera, te broj značajki bio tek nešto manji nego broj svih značajki. Najlošiji rezultati dobiveni su u predviđanju rezolucije jer

promjena rezolucije nije utjecala na mrežni promet, za razliku od brzine kodiranja i broja okvira u sekundi.

7. Sažetak

Zbog lakoće pristupa igre zasnovane na računalnom oblaku stječu sve veću popularnost među igračima, uz to izdavačima daju pristup široj publici i rješavaju problem piratizacije. Uz razvoj 5G mreža ovaj oblik igranja bi trebao biti još pristupačniji.

U ovome radu je analiziran utjecaj promjene parametara brzine kodiranja, broja okvira u sekundi i rezolucije na prostorne i vremenske video metrike, kao i analiza utjecaja tih istih parametara na mrežne podatke. Također su korištene tehnike strojnog učenja kako bi se predvidjeli rezolucija, brzine kodiranja i broj okvira u sekundi iz snimljenog mrežnog prometa za svaku odigranu sjednicu. Pri analizi utjecaja parametara na video metrike ustanovljeno je da promjena rezolucije ima velik utjecaj na prostorne, a promjena broja okvira u sekundi ima utjecaj na vremenske video metrike. Brzina kodiranja nije imala nikakvog utjecaja ni na prostorne ni na vremenske metrike. Također je uočeno da igre iz prvog i trećeg lica imaju visoke vremenske i niske prostorne metrike, dok igre s pogledom odozgo imaju niske vremenske i visoke prostorne video metrike. Analizom mrežnog prometa utvrdili smo da povećanjem brzine kodiranja, poveća se broj paketa kao i veličina paketa koje se šalju. Za igre koje se oslanjaju na igranjem mišem klijent bi slao puno više prometa prema poslužitelju, nego za igre koje se igraju isključivo pomoću tipkovnice. Korištenjem tehnika strojnog učenja iz mrežnih podataka moglo se s velikom preciznošću predvidjeti korisnička brzina kodiranja i broj okvira u sekundi, dok predviđanje rezolucije igre u najboljem slučaju je bilo točno u 70 % slučajeva.

Ključne riječi: Igre zasnovane na računalom oblak, Steam Remote Play, Strojno učenje, Metrike prostorne i vremenske složenosti videozapisa

8. Summary

Due to the ease of access, cloud gaming is gaining increasing popularity among gamers. In addition to that, it gives game publishers wider reach while also solving the problem of video game piracy. With the development of 5G networks, this form of gaming should be even more accessible.

This thesis analyzes the impact of bitrate, framerate and resolution on spatial and temporal video metrics, as well as their impact on network traffic. Machine learning was used to predict the resolution, bitrate and framerate from network data for each recorded session. When analyzing the influence of parameters on video metrics, it was determined that changing the resolution has a large impact on spatial metrics, while changing the framerate has an impact on temporal video metrics. Bitrate had no effect on either spatial or temporal metrics. It has also been observed that first and third person games have high temporal and low spatial metrics, while top down games have low temporal and high spatial video metric values. By analyzing network traffic, it was found that by increasing bitrate, the number of packets as well as packet size increased. For games that relied on mouse use, the client would send a lot more traffic data to the server than for games which were played solely using the keyboard. By using machine learning on traffic data, it is possible to predict bitrate and framerate with great accuracy, while predicting resolution was at best 70 % accurate.

Key words: Cloud gaming, Steam Remote Play, Machine learning, Spatial and temporal video metrics

Literatura

[1]. Mell, Peter, and Tim Grance. "The NIST Definition of Cloud Computing." National Institute of Standards and Technology, September 28, 2011. https://doi.org/10.6028/NIST.SP.800-145.

[2]. Slack. "Slack Is Where the Future Works." Slack. Zadnji pristup: June 13, 2022. https://slack.com/.

[3]. "HubSpot | Best Free CRM Software for Businesses." Zadnji pristup: June 13, 2022. https://www.hubspot.com/products/crm.

[4]. Dropbox. "Store, Share, Collaborate and More with Dropbox." Zadnji pristup: June 13, 2022. https://www.dropbox.com/

[5]. "Cloud Computing Services | Microsoft Azure." Zadnji pristup: June 13, 2022. https://azure.microsoft.com/en-us/.

[6]. Google Cloud. "App Engine Documentation | App Engine Documentation." Zadnji pristup: June 13, 2022. https://cloud.google.com/appengine/docs.

[7]. Amazon Web Services, Inc. "AWS Elastic Beanstalk – Deploy Web Applications." Zadnji pristup: June 13, 2022. https://aws.amazon.com/elasticbeanstalk/.

[8]. Amazon Web Services, Inc. "Secure and Resizable Cloud Compute – Amazon EC2 – Amazon Web Services." Zadnji pristup: June 13, 2022. https://aws.amazon.com/ec2/.

[9]. Google Cloud. "Compute Engine Documentation | Compute Engine Documentation." Zadnji pristup: June 13, 2022. https://cloud.google.com/compute/docs.

[10]. "SoftLayer on IBM Cloud | IBM." Zadnji pristup: June 13, 2022. https://www.ibm.com/cloud/info/softlayer-is-now-ibm-cloud.

[11]. "The Global Cloud Computing Market Size Is Expected to Grow from USD 445.3 Billion in 2021 to USD 947.3 Billion by 2026, at a Compound Annual Growth Rate (CAGR) of 16.3%." Zadnji pristup: June 13, 2022. https://finance.yahoo.com/news/global-cloud-computing-market-size-081600295.html.

[12]. Shea, Ryan, Jiangchuan Liu, Edith C.-H. Ngai, and Yong Cui. "Cloud Gaming: Architecture and Performance." IEEE Network 27, no. 4 (July 2013): 16–21. https://doi.org/10.1109/MNET.2013.6574660.

[13]. BBC News. "The Great Graphics Card Shortage of 2020 (and 2021)," January 24, 2021, sec. Technology. https://www.bbc.com/news/technology-55755820.

[14]. PlayStation. "PS Now | On-Demand PlayStation Games on PS5, PS4 or PC." Zadnji pristup: June 13, 2022. https://www.playstation.com/en-us/ps-now/.

[15]. "GNS_E.Pdf." Zadnji pristup: June 13, 2022. https://www.sony.com/en/SonyInfo/IR/library/presen/irday/pdf/2021/GNS_E.pdf.

[16]. "Stadia – One Place for All the Ways We Play." Zadnji pristup: June 13, 2022. https://stadia.google.com/.

[17]. "Your Games. Your Devices. Play Anywhere | NVIDIA GeForce NOW." Zadnji pristup: June 13, 2022. https://www.nvidia.com/en-eu/geforce-now/.

[18]. Transcribers, Motley Fool. "NVIDIA Corporation (NVDA) Q3 2021 Earnings Call Transcript." The Motley Fool, November 18, 2021. https://www.fool.com/earnings/call-transcripts/2021/11/18/nvidia-corporation-nvda-q3-2021-earnings-call-tran/.

[19]. "Amazon Luna – Cloud Gaming Service." Zadnji pristup: June 13, 2022. https://www.amazon.com/luna/landing-page.

[20]. Xbox.com. "Xbox Cloud Gaming (Beta) with Xbox Game Pass | Xbox." Zadnji pristup: June 13, 2022. https://www.xbox.com/en-US/xbox-game-pass/cloud-gaming.

[21]. Ivan Slivar, Kresimir Bačić, Irena Oršolić, Lea Skorin-Kapov, Mirko Sužnjević, "CGD: A Cloud Gaming Dataset with Gameplay Video and Network Recordings", ACM Multimedia Systems, 2022, Irska.

[22]. "Steam Store." Zadnji pristup: June 13, 2022. https://store.steampowered.com/.

[23]. "Steam :: Steamworks Development :: Steam - 2020 Year in Review," January 13, 2021. https://store.steampowered.com/news/group/4145017/view/2961646623386540826 .

[24]. "Steam Link on Steam." Zadnji pristup: June 13, 2022. https://store.steampowered.com/app/353380/Steam_Link/.

[25]. "Steam Support :: Steam Remote Play." Zadnji pristup: June 13, 2022. https://help.steampowered.com/en/faqs/view/0689-74B8-92AC-10F2.

[26]. "Wireshark · Go Deep." Zadnji pristup: June 13, 2022. https://www.wireshark.org/.

[27]. "FRAPS Show Fps, Record Video Game Movies, Screen Capture Software." Zadnji pristup: June 13, 2022. https://fraps.com/.

[28]. "Macro Recorder - No More Repetitive Tasks - Mouse and Keyboard Capture." Zadnji pristup: June 13, 2022. https://www.macrorecorder.com/.

[29]. "Tshark(1)." Zadnji pristup: June 13, 2022. https://www.wireshark.org/docs/man-pages/tshark.html.

[30]. Claypool, Mark. "MotFion and Scene Complexity for Streaming Video Games." In Proceedings of the 4th International Conference on Foundations of Digital Games, 34–41. FDG '09. New York, NY, USA: Association for Computing Machinery, 2009. https://doi.org/10.1145/1536513.1536529.

[31]. "P.910 : Subjective Video Quality Assessment Methods for Multimedia Applications." Zadnji pristup: June 13, 2022. https://www.itu.int/rec/T-REC-P.910.

[32]. Janiesch, Christian, Patrick Zschech, and Kai Heinrich. "Machine Learning and Deep Learning." *Electronic Markets* 31, no. 3 (September 1, 2021): 685–95. https://doi.org/10.1007/s12525-021-00475-2.

[33]. Mohri, Mehryar, Afshin Rostamizadeh, and Ameet Talwalkar. *Foundations of Machine Learning*. 2nd ed. Adaptive Computation and Machine Learning Series. Cambridge, MA, USA: MIT Press, 2018.

[34]. Orsolic, Irena, and Michael Seufert. "On Machine Learning Based Video QoE Estimation Across Different Networks." In *2021 16th International Conference on Telecommunications (ConTEL)*, 62–69, 2021. https://doi.org/10.23919/ConTEL52528.2021.9495971.

[35]. "Scikit-Learn: Machine Learning in Python — Scikit-Learn 1.1.1 Documentation." Zadnji pristup: June 14, 2022. https://scikit-learn.org/stable/.

[36]. Python.org. "Welcome to Python.Org." Zadnji pristup: June 14, 2022. https://www.python.org/.

[37]. "Pandas - Python Data Analysis Library." Zadnji pristup: June 14, 2022. https://pandas.pydata.org/.

[38]. scikit-learn. "Sklearn.Preprocessing.StandardScaler." Zadnji pristup: June 14, 2022. https://scikit-learn/stable/modules/generated/sklearn.preprocessing.StandardScaler.html.

[39]. Breiman, Leo. "Random Forests." *Machine Learning* 45, no. 1 (October 1, 2001): 5–32. https://doi.org/10.1023/A:1010933404324.

[40]. scikit-learn. "1.4. Support Vector Machines." Zadnji pristup: June 14, 2022. https://scikit-learn/stable/modules/svm.html.

[41]. "What Is Logistic Regression? | IBM." Zadnji pristup: June 15, 2022. https://www.ibm.com/topics/logistic-regression.

[42]. Analytics India Magazine. “A Beginner’s Guide To Scikit-Learn’s MLPClassifier,” June 20, 2019. https://analyticsindiamag.com/a-beginners-guide-to-scikit-learns-mlpclassifier/.
[43]. “Predavanja - Neuronske Mreže.” Zadnji pristup: June 15, 2022. https://www.fer.unizg.hr/_download/repository/06-ViseslojniPerceptron.pdf.
[44]. scikit-learn. “Sklearn.Ensemble.RandomForestClassifier.” Zadnji pristup: June 22, 2022. https://scikit-learn/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html.
[45]. B, Harikrishnan N. “Confusion Matrix, Accuracy, Precision, Recall, F1 Score.” *Analytics Vidhya* (blog), June 1, 2020. https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd.
[46]. Cai, Wei, Ryan Shea, Chun-Ying Huang, Kuan-Ta Chen, Jiangchuan Liu, Victor C. M. Leung, and Cheng-Hsin Hsu. “A Survey on Cloud Gaming: Future of Computer Games.” *IEEE Access* 4 (2016): 7605–20. https://doi.org/10.1109/ACCESS.2016.2590500.
[47]. “Nastavni Materijali - Strojno Učenje.” Zadnji pristup: June 21, 2022. https://www.fer.unizg.hr/_download/repository/SU-2020-21-VrednovanjeModela.pdf

Popis slika

Slika 2.1 Arhitektura igara zasnovanih na računalnom oblaku [46] 4
Slika 4.1 Steam Remote Play arhitektura [25] 10
Slika 4.2 Primjer .pcap datoteke: mrežni promet snimljen tijekom igranja 12
Slika 4.3 Primjer Steam streaming_log.txt datoteke 13
Slika 5.1 Kategorizacije igara prema IBS/PFIM vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps 17
Slika 5.2 Kategorizacije igara prema IBS/PFIM vrijednostima za parametre postavljene na 5 Mbit/s-720p-30fps 18
Slika 5.3 IBS/PFIM vrijednost igre Alan Wake pri kombinaciji parametara 5 Mbit/s-720p-60 fps za svih pet snimanja unutar kombinacije 19
Slika 5.4 IBS/PFIM vrijednosti za igre Alan Wake, Dota 2 i Shadow Tactics pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps 20
Slika 5.5 IBS/PFIM vrijednosti za igre Deus Ex Mankind Divided, Endless Space i Red Alert 3 pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps 20
Slika 5.6 IBS/PFIM vrijednosti za igre Alan Wake, Dota 2 i Shadow Tactics pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 1080p-60 fps 21
Slika 5.7 IBS/PFIM vrijednosti za igre Burnout Paradise, Batman Arkham Knight i Company of Heroes pri različitim rezolucijama i ostalim parametrima postavljenim na 20 Mbit/s-30 fps 22
Slika 5.8 IBS/PFIM vrijednosti za igre Doom, Ring of Pain i Shadow Tactics pri različitim rezolucijama i ostalim parametrima postavljenim na 5 Mbit/s-30 fps 23
Slika 5.9 IBS/PFIM vrijednosti za igre Tomb Raider, Company of Heroes 2 i Endless Space pri različitim brojevima okvira i ostalim parametrima postavljenim na 20 Mbit/s-720p 24
Slika 5.10 IBS/PFIM vrijednosti za igre Darksiders 3, Shadow Tactics i Ring of Pain pri različitim brojevima okvira i ostalim parametrima postavljenim na 10Mbit/s-1080p 25
Slika 5.11 Kategorizacije igara prema SI/TI (prosjek) vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps 26

Slika 5.12 Kategorizacije igara prema SI/TI (maksimum) vrijednostima za parametre postavljene na 20 Mbit/s-1080p-60 fps 27
Slika 5.13 Kategorizacije igara prema SI/TI (prosjek) vrijednostima za parametre postavljene na 5 Mbit/s-720p-30 fps 28
Slika 5.14 Kategorizacije igara prema SI/TI (maksimalne) vrijednostima za parametre postavljene na 5 Mbit/s-720p-30 fps 28
Slika 5.15 SI/TI vrijednosti za igre Dirt 5, Darksiders 3, Endless Space 2 i Batman Arkham Knight pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 1080p-60 fps 29
Slika 5.16 SI/TI vrijednosti za igre Dirt 5, Darksiders 3, Endless Space 2 i Batman Arkham Knight pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 720p-30 fps 30
Slika 5.17 SI/TI vrijednosti za igre Deus Ex Mankind Divided, Ring of Pain, Company of Heroes 2 i Prey pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 20 Mbit/s-30 fps 31
Slika 5.18 SI/TI vrijednosti za igre Deus Ex Mankind Divided, Ring of Pain, Company of Heroes 2 i Prey pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 5 Mbit/s-30 fps 32
Slika 5.19 SI/TI vrijednosti za igre Doom, Endless Space 2, Dirt 5 i Divinity Original Sin pri različitim brzinama kodiranja i ostalim parametrima postavljenim na 20 Mbit/s-720p 33
Slika 5.20 Veličina paketa/Propusnost za sve igre pri parametrima 20 Mbit/s-1080p-60 fps 34
Slika 5.21 Veličina paketa/Propusnost za sve igre pri parametrima 5 Mbit/s-720p-30 fps 35
Slika 5.22 Veličina paketa/broj paketa Alan Wake (1080p-60 fps) 36
Slika 5.23 Veličina paketa/broj paketa Burnout Paradise (720p-30 fps) 37
Slika 5.24 Veličina paketa/Propusnost graf utjecaj promjene broja okvira u sekundi za igre Borderlands 2, Grim Dawn, Dirt 5 (20Mbit/s-1080p) 38
Slika 5.25 Veličina paketa/Propusnost graf utjecaj promjene broja okvira u sekundi za igre Borderlands 2, Grim Dawn, Dirt 5 (5 Mbit/s-720p) 38
Slika 5.26 Kategorizacija igara prema broju paketa i veličini paketa - promet klijent-server 39
Slika 6.1 Primjer matrice zabune za binarnu klasifikaciju broja okvira u sekundi 43
Slika 6.2 Matrica zabune (Logistička regresija) - predviđanje brzine kodiranja 47

Slika 6.3 Matrica zabune (Logistička regresija) - predviđanje brzine kodiranja uz izbor najboljih značajki (RandomForestClassifier) 48
Slika 6.4 Matrica zabune (Klasifikator slučajnih šuma) - predviđanje brzine kodiranje 49
Slika 6.5 Matrica zabune (Metoda potpornih vektora) - predviđanje brzine kodiranje 51

Popis tablica

Tablica 4.1 Steam Link dostupna ograničenja brzine kodiranja, broja okvira u sekundi i rezolucije 9
Tablica 4.2 Testirane igre 11
Tablica 6.1 Rezultati klasifikacije brzine kodiranja koristeći logističku regresiju..... 46
Tablica 6.2 Rezultati klasifikacije brzine kodiranja koristeći klasifikator slučajnih šuma . 49
Tablica 6.3 Rezultati klasifikacije brzine kodiranja koristeći metode potpornih vektora ... 50
Tablica 6.4 Rezultati klasifikacije broja okvira u sekundi koristeći logističku regresiju.... 52
Tablica 6.5 Rezultati klasifikacije broja okvira u sekundi koristeći klasifikator slučajnih šuma..... 52
Tablica 6.6 Rezultati klasifikacije brzine kodiranja koristeći metode potpornih vektora ... 53
Tablica 6.7 Rezultati klasifikacije rezolucije koristeći logističku regresiju 54
Tablica 6.8 Rezultati klasifikacije rezolucije koristeći klasifikator slučajnih šuma..... 54
Tablica 6.9 Rezultati klasifikacije rezolucije koristeći metode potpornih vektora 55